

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E METEOROLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

Bruno José Bonho Link Barbosa

**ANÁLISE ORIENTADA A OBJETOS PARA A CLASSIFICAÇÃO DE USO E
COBERTURA DA TERRA COM IMAGENS DE VANT E DE NANOSSATÉLITES**

PORTO ALEGRE

2021

BRUNO JOSÉ BONHO LINK BARBOSA

**ANÁLISE ORIENTADA A OBJETOS PARA A CLASSIFICAÇÃO DE USO E
COBERTURA DA TERRA COM IMAGENS DE VANT E DE NANOSSATÉLITES**

Dissertação apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto como requisito parcial para a obtenção do título de mestre em Sensoriamento Remoto e Geoprocessamento.

Orientador: Prof. Dr. Cláudio Wilson Mendes Júnior

Coorientador: Prof. Dr. Marcos Wellausen Dias de Freitas

PORTO ALEGRE

2021

CIP - Catalogação na Publicação

Barbosa, Bruno José Bonho Link
ANÁLISE ORIENTADA A OBJETOS PARA A CLASSIFICAÇÃO
DE USO E COBERTURA DA TERRA COM IMAGENS DE VANT E DE
NANOSSATÉLITES / Bruno José Bonho Link Barbosa. --
2021.

58 f.

Orientador: Cláudio Wilson Mendes Júnior.

Coorientador: Marcos Wellausen Dias de Freitas.

Dissertação (Mestrado) -- Universidade Federal do
Rio Grande do Sul, Centro Estadual de Pesquisas em
Sensoriamento Remoto e Meteorologia, Programa de
Pós-Graduação em Sensoriamento Remoto, Porto Alegre,
BR-RS, 2021.

1. Structure from Motion. 2. Fotogrametria. 3.
GEOBIA. 4. Nanossatélites. I. Mendes Júnior, Cláudio
Wilson, orient. II. de Freitas, Marcos Wellausen
Dias, coorient. III. Título.

PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

DISSERTAÇÃO

Submetida como parte dos requisitos
para obtenção do Grau de

MESTRE EM SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

Programa de Pós-Graduação em Sensoriamento Remoto (PPGSR)
Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPRSM)
Universidade Federal do Rio Grande do Sul (UFRGS)
Porto Alegre, RS, Brasil.

Aprovada em: 27/09/2021.

Homologada em: ____/____/2021.

Pela Banca Examinadora:

Por:



Prof. Dr. Cláudio Wilson Mendes Júnior
Orientador

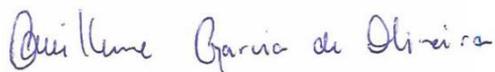
Prof. Dr. Guilherme Garcia de Oliveira
Coordenador do Programa de Pós-
Graduação em Sensoriamento Remoto



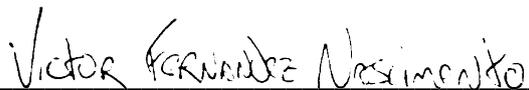
Prof. Dr. Marcos Wellausen Dias de
Freitas
Coorientador



Profa. Dra. Kátia Kellem da Rosa
(UFRGS)



Prof. Dr. Guilherme Garcia de Oliveira
(PPGSR/UFRGS)



Prof. Dr. Victor Fernandez Nascimento
(PPGSR/UFRGS)

AGRADECIMENTOS

Agradeço aos meus familiares pelo apoio incondicional. Em especial aos meus pais, José e Márcia pelo carinho e incentivo na busca por conhecimento, e minha irmã Elisa, por estar sempre ao meu lado;

À minha companheira Elisa, pelo estímulo, amparo e aconselhamentos;

À Universidade Federal do Rio Grande do Sul, pela estrutura disponibilizada para a minha formação acadêmica e para o desenvolvimento desta dissertação;

Ao Programa de Pós-Graduação em Sensoriamento Remoto;

Aos colaboradores do Departamento de Geodésia, Éder Luís da Silva Rodrigues e Robson dos Santos Aquino, pelo auxílio nos trabalhos de campo; e

Aos professores Cláudio Wilson Mendes Júnior e Marcos Wellausen de Freitas, pela partilha de seus conhecimentos, pela disposição em me auxiliarem na criação do projeto de pesquisa e pela confiança depositada em meu trabalho.

RESUMO

O advento de plataformas como os Veículos Aéreos Não Tripulados (VANT), juntamente com o surgimento de novas técnicas fotogramétricas, como o algoritmo *Structure From Motion*, tem possibilitado a melhora do mapeamento em ambientes urbanos e rurais. As imagens de VANT permitem uma análise detalhada da superfície terrestre para a produção de informações cartográficas, em sua maioria, por meio da interpretação visual e extração manual de informações. Porém, devido à baixa resolução espectral das imagens obtidas pelos VANT mais difundidos no mercado, o uso de técnicas de classificação automática não é uma prática corriqueira. O presente trabalho explora o uso combinado de fotografias obtidas por VANT e de imagens multiespectrais de nanossatélites para a classificação do uso e cobertura da terra de área rural por meio da abordagem GEOBIA. Para tanto, foram realizadas: (i) aquisição e processamento de imagens de VANT e de nanossatélites; (ii) fusão por transformação IHS para aumentar a resolução espacial da imagem do Infravermelho Próximo (NIR) dos nanossatélites (iii); segmentação das imagens; (iv) definição de seis conjuntos de dados para a avaliação da contribuição de seus atributos na acurácia da classificação; (v) classificação dos seis conjuntos de dados empregando os classificadores por árvore de decisão (AD) *Random Forest* (RF) e Boosted C5.0; e (vi) avaliação da acurácia das classificações geradas. O melhor resultado encontrado foi obtido pelo RF, atingindo valores de exatidão global de 0,867 e de índice Kappa de 0,854 na classificação feita a partir do uso de todos os conjuntos de dados nesse algoritmo. Os atributos gerados a partir dos dados de NIR, oriundos das imagens orbitais, não contribuíram para o aumento na exatidão da classificação. Por outro lado, os atributos derivados do Modelo Digital de Superfície (MDS) foram os mais importantes para melhorar a qualidade da classificação do ortofotomosaico. Os resultados mostraram que fotografias obtidas com câmeras de baixo custo acopladas a VANT e que o MDS derivado dessas imagens podem ser usados para gerar mapas precisos de cobertura e uso da terra de áreas rurais, a partir do emprego de classificadores baseados na abordagem GEOBIA e no classificador *Random Forest*.

Palavras-chave: *Structure from Motion, Fotogrametria, GEOBIA, Nanossatélites.*

ABSTRACT

The advent of platforms such as Unmanned Aerial Vehicles (UAV), along with the emergence of new photogrammetric techniques, such as the Structure From Motion algorithm, has made it possible to improve mapping of urban and rural areas. UAV images allow a detailed analysis of the Earth's surface for the production of cartographic information, mostly through visual interpretation and manual digitalization of classes. However, due to the low spectral resolution of images obtained by the most UAV cameras available on the market, the use of automatic classification techniques is not a current methodology. The present work explores the combined use of UAV photographs and multispectral images from nanosatellites for the classification of land use and land cover areas through the GEOBIA approach. For this purpose, we performed: (i) acquisition and processing of UAV and nanosatellite images; (ii) applying the IHS Pan-sharpening technique to enhance the spatial resolution of the Near Infrared (NIR) image of nanosatellites (iii); segmentation of these images; (iv) definition of six data sets and derived attributes for the evaluation of their contributions to the classification accuracy; (v) use of these attributes in the decision tree (DT) classifiers Random Forest (RF) and Boosted C5.0; and (vi) accuracy assessment of the classifications. The best result was found by using the RF, reaching global accuracy values of 0.867 and Kappa index of 0.854 in the classification performed from the use of all data sets in this algorithm. The attributes generated from the NIR data from the orbital images would not contribute to the increase of classification accuracy. On the other hand, the attributes derived from the Digital Surface Model (DSM) were the most important to improve the quality of the orthophoto mosaic classification. The results showed that photographs taken with low-cost cameras coupled with UAV and the DSM derived from these images by photogrammetric techniques can be used to generate accurate maps for the classification of land use and land cover of rural areas, through the application of the GEOBIA approach and the RF classifier.

Keywords: Structure of Motion, Photogrammetry, GEOBIA, Nanosatellites.

LISTA DE ILUSTRAÇÕES

| | |
|---|----|
| Figura 1 - Fluxograma metodológico..... | 30 |
| Figura 2 - Localização da área de estudo sobre composição colorida RGB 321 de imagem do nanossatélite PlanetScope, obtida em 06/09/2018..... | 31 |
| Figura 3 - DJI Phantom 3 Advanced | 33 |
| Figura 4 - Receptor GNSS Hiper Lite+ | 33 |
| Figura 5 - Etapas do levantamento fotogramétrico..... | 34 |
| Figura 6 - Localização dos GCP na área de estudo..... | 35 |
| Figura 7 - Plano de voo no aplicativo Drone Deploy | 36 |
| Figura 8 - Modelo Digital de Superfície. | 39 |
| Figura 9 - Mosaico de Ortofotos. | 40 |
| Figura 10 - Dados utilizados para a classificação. | 42 |
| Figura 11 - Amostras de treinamento e de validação. | 45 |
| Figura 12 - Classificação por Random Forest (processamento do conjunto 6). | 48 |
| Figura 13 - Classificação pelo algoritmo C5.0 (processamento do conjunto 5). | 49 |
| Figura 14 - Valores de Exatidão Global e Índice Kappa para as classificações com o algoritmo Random Forest. | 50 |
| Figura 15 - Valores de Exatidão Global e Índice Kappa para as classificações com o algoritmo C5.0..... | 51 |
| Figura 16 - Uso e cobertura da terra pelo algoritmo Random Forest para o conjunto 1 (a); conjunto 2 (b); conjunto 3 (c); conjunto 4 (d); conjunto 5 (e); e conjunto 6 (f) | 53 |
| Figura 17 - Uso e cobertura da terra pelo algoritmo C.5.0 para o conjunto 1 (a); conjunto 2 (b); conjunto 3 (c); conjunto 4 (d); conjunto 5 (e); e conjunto 6 (f) | 54 |
| Figura 18 - Mean Decrease Accuracy para os algoritmos Random Forest e C5.0 (conjunto 6) | 55 |
| Figura 19 - Acurácia do produtor e do usuário por classe para as classificações realizadas com Random Forest..... | 56 |
| Figura 20 - Acurácia do produtor e do usuário por classe para as classificações realizadas com C5.0..... | 57 |

LISTA DE TABELAS

| | |
|--|----|
| Tabela 1 - Características do CubeSat 3U e de seu sensor multiespectral | 19 |
| Tabela 2 - Características dos Produtos PlanetScope | 20 |
| Tabela 3 - Exemplo de matriz de confusão | 27 |
| Tabela 4 - Atributos vinculados aos segmentos das imagens..... | 43 |
| Tabela 5 - Atributos por conjunto de processamento | 44 |
| Tabela 6 - Valores mínimo, máximo média e desvio-padrão por camada de informação das amostras de treinamento (os níveis digitais das imagens RGB e valores de reflectância estão escalonados para 10.000 nas imagens NIR)..... | 47 |
| Tabela 7 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo Random Forest para o conjunto 1 | 80 |
| Tabela 8 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo Random Forest para o conjunto 2 | 80 |
| Tabela 9 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo Random Forest para o conjunto 3 | 81 |
| Tabela 10 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo Random Forest para o conjunto 4 | 81 |
| Tabela 11 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo Randon Forest para o conjunto 5 | 82 |
| Tabela 12 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo Randon Forest para o conjunto 6 | 82 |
| Tabela 13 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo C5.0 para o conjunto 1 | 83 |
| Tabela 14 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo C5.0 para o conjunto 2 | 83 |
| Tabela 15 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo C5.0 para o conjunto 3 | 84 |
| Tabela 16 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo C5.0 para o conjunto 4 | 84 |
| Tabela 17 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo C5.0 para o conjunto 5 | 85 |
| Tabela 18 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo C5.0 para o conjunto 6 | 85 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|-----------|---|
| ANAC | Agência Nacional de Aviação Civil |
| ARPs | Aeronaves Remotamente Pilotadas |
| BOA | <i>Bottom of Atmosphere</i> |
| C5.0 | <i>Boosted C5.0</i> |
| CCD | <i>Charge-Couple Device</i> |
| CMOS | <i>Complementary Metal Oxide Semiconductor</i> |
| DN | <i>Digital Number</i> |
| DSM | <i>Digital Surface Model</i> |
| DT | <i>Decision Tree</i> |
| EAA/UFRGS | Estação Experimental Agronômica da Universidade Federal do Rio Grande do Sul |
| EG | Exatidão Global |
| GCP | <i>Ground Control Points</i> |
| GEOBIA | <i>Geographic Image Analysis Based</i> |
| GLCM | <i>Gray-Level Co-Occurrence Matrix</i> |
| GNSS | <i>Global Navigation Satellite System</i> |
| GSD | <i>Ground Sample Distance</i> |
| HIS | <i>Intensity Hue Saturation</i> |
| IK | Índice Kappa |
| KNN | <i>K-Nearest Neighbor</i> |
| LiDAR | <i>Light Detection and Ranging</i> |
| MDS | Modelo Digital de Superfície |
| MODIS NRT | <i>Moderate Resolution Imaging Spectroradiometer- Near Real-Time Global Flood</i> |
| MVS | <i>Multi-View Stereo</i> |
| NIR | <i>Near Infrared</i> |
| PAN | Pancromática |
| PCA | <i>Principal Component Analysis</i> |
| PDI | Processamento Digital de Imagens |
| RF | <i>Random Forest</i> |
| RGB | <i>Red/Green/Blue</i> |
| RSF | <i>Radiometric Scale Factor</i> |

| | |
|--------|--|
| SfM | <i>Structure from Motion</i> |
| SIFT | <i>Scale Invariant Feature Transform</i> |
| SISANT | Sistema de Aeronaves não Tripuladas |
| SVM | <i>Support Vector Machine</i> |
| TIN | <i>Triangular Irregular Network</i> |
| TOA | <i>Top of Atmosphere</i> |
| UAV | <i>Unmanned Aerial Vehicles</i> |
| UTM | Universal Transversa de Mercator |
| VANT | Veículo Aéreo Não Tripulado |

SUMÁRIO

| | | |
|-------|--|----|
| 1 | INTRODUÇÃO..... | 12 |
| 2 | OBJETIVOS..... | 14 |
| 2.1 | Objetivo geral..... | 14 |
| 2.2 | Objetivos específicos..... | 14 |
| 3 | REFERENCIAL TEÓRICO..... | 15 |
| 3.1 | Fotogrametria com VANTS por <i>Structure From Motion</i> | 15 |
| 3.2 | Imagens de nanossatélites..... | 17 |
| 3.3 | Métodos de fusão de imagens..... | 21 |
| 3.4 | Análise de imagens baseada em objetos geográficos..... | 23 |
| 3.5 | Avaliação da acurácia da classificação..... | 27 |
| 4 | PROCEDIMENTOS METODOLÓGICOS..... | 30 |
| 4.1 | Localização e caracterização da área de estudo..... | 31 |
| 4.2 | Plataformas e sensores utilizados..... | 32 |
| 4.3 | Levantamento aerofotogramétrico com VANT..... | 34 |
| 4.3.1 | Planejamento..... | 34 |
| 4.3.2 | Aquisição dos dados em campo..... | 36 |
| 4.3.3 | Processamento Fotogramétrico..... | 37 |
| 4.4 | Aquisição e processamento dos dados orbitais do nanossatélite..... | 41 |
| 4.5 | Fusão das imagens fotogramétricas e orbitais..... | 41 |
| 4.6 | GEOBIA..... | 42 |
| 5 | RESULTADOS E DISCUSSÕES..... | 46 |
| 6 | CONCLUSÕES..... | 59 |
| 7 | REFERÊNCIAS..... | 61 |
| 8 | ANEXOS..... | 71 |

| | | |
|-----|--|----|
| 8.1 | ANEXO I: Relatório dos pontos de apoio processados no <i>software</i> TOPCON TOOLS..... | 71 |
| 8.2 | ANEXO II: Relatório de processamento fotogramétrico realizado no <i>software</i> Agisoft Metashape | 74 |
| 8.3 | ANEXO III: Tabelas de acurácias das classificações | 80 |

1 INTRODUÇÃO

De acordo com Moreira (2001), no Sensoriamento Remoto os sistemas sensores podem ser mantidos no nível orbital (satélites) ou suborbital (acoplados a aeronaves ou mantidos ao nível do solo). O advento dos veículos aéreos não tripulados (VANT) de baixo custo, utilizados para aquisição de dados de sensoriamento remoto, e o desenvolvimento de algoritmos que possibilitam o processamento destes dados, resultaram em novas formas de produção de dados tridimensionais por meio de fotogrametria (REMONDINO, 2014). Outra inovação no campo do sensoriamento remoto é o desenvolvimento de satélites em miniatura, chamados de pequenos satélites ou Cubesats, com lançamento relativamente barato e com sensores de rápida construção (CRUSAN e GALICA, 2019).

Uma das dificuldades na produção de imagens do uso e cobertura da terra com alta definição das feições é o desafio de conseguir imagens com alta resolução espacial e temporal (BERNI *et al.*, 2009). Os sensores orbitais tiveram progresso considerável nesse aspecto, mas são restritos pela óptica, largura de banda ou configurações orbitais que limitam as características espaço-temporais. Uma abordagem que foi proposta para superar essas limitações é o uso de constelações de nanossatélites, que consistem em um grande número de unidades sensoras, pequenas e compactas, que são tipicamente baratas, substituíveis e tiram proveito de economias de escala (ESPER *et al.*, 2000).

Nos últimos anos, houve também um crescente interesse na utilização de imagens geradas por VANT (HALL *et al.*, 2018; BÖHLER *et al.*, 2018; PAJARES 2015; SHAHBAZI *et al.*, 2014; LATIF, 2018). Para o processamento dos dados gerados pelos veículos aéreos não tripulados foi necessária a evolução de *hardware* e também de *software*, com a implementação de novas técnicas fotogramétricas, tal como o *Structure From Motion* (CARRIVICK *et al.*, 2016). A vantagem das imagens obtidas por essas plataformas sobre as imagens de satélite é, em geral, a sua capacidade de fornecer imagens com resoluções espacial e temporal muito mais altas (LATIF, 2018).

Alguns estudos aplicaram uma abordagem multisensor, visando aproveitar ao máximo as potencialidades desses sensores suborbitais com sensores orbitais (satélites) (ZHAO *et al.*, 2019; YILMAZ e GUNGOR 2016; JENEROWICZ e

WOROSZKIEWICZ, 2016). Zhao *et al.* (2019). realizaram a fusão de imagens Sentinel-2a com imagens de câmera de um VANT, para mapear a distribuição de culturas em uma área agrícola, com resultados indicando que as imagens fusionadas possibilitaram obter maior precisão na classificação do que com o uso das imagens originais.

O banco de dados de registros da Agência Nacional de Aviação Civil (ANAC) aponta que a quantidade de veículos aéreos não tripulados registrados para uso profissional no Sistema de Aeronaves não Tripuladas (SISANT) aumentou nos últimos anos, passando de 11167 aeronaves em 2017, para um total de 35943 em agosto de 2021 (ANAC, 2021). A maior parte desses equipamentos são de relativo baixo custo, e com sensores acoplados de baixa resolução espectral. Geralmente a extração de informações dessas imagens ocorre por um processo manual e trabalhoso, a partir da interpretação visual de feições.

Essas plataformas, equipadas com câmeras não métricas, são uma alternativa para coletar imagens com alta resolução espacial (TURNER *et al.*, 2012). Porém, as imagens com resolução espacial submétrica coletadas por essa metodologia possuem alta variabilidade espectral, dificultando a classificação da cobertura da terra. A redução da variabilidade espectral dessas imagens pode ser obtida a partir da Análise de Imagens Baseada em Objetos Geográficos (do inglês: *Geographic Object-Based Image Analysis – GEOBIA*) (LECHNER *et al.*, 2012).

Assim, a hipótese desse trabalho é que métodos de fusão de imagens fotográficas de VANTs com imagens multiespectrais de nanossatélites podem melhorar a acurácia de classificação do uso e cobertura da terra, bem como a detecção dessas classes pode ser ainda aprimorada com o uso adicional de seus atributos espaciais e texturais, com a aplicação de GEOBIA.

2 OBJETIVOS

2.1 Objetivo geral

Aplicar a abordagem de GEOBIA para a classificação de uso e cobertura da terra em imagens de sensoriamento remoto obtidas por VANT e dados de nanossatélites.

2.2 Objetivos específicos

- a) Adquirir e processar imagens obtidas por um VANT, para a geração de ortofotomosaicos e de Modelo Digital de Superfície (MDS) da área de estudo;
- b) Realizar o fusionamento da ortoimagem gerada (resolução espacial de 10 cm) com imagens síncronas da banda espectral do infravermelho próximo (3 m) da constelação PlanetScope;
- c) Avaliar a acurácia das classificações de uso e cobertura da terra obtidas a partir do uso de diferentes conjuntos de dados e algoritmos de GEOBIA, a partir de ortofotomosaico, MDS e da imagem fusionada produzida.

3 REFERENCIAL TEÓRICO

Neste capítulo são apresentados uma revisão dos conceitos e das técnicas de processamento digital das imagens fotogramétricas obtidas através de VANT e dos dados orbitais oriundos de nanossatélites. Também são descritos os métodos de fusão de dados multisensores e da avaliação da acurácia de algoritmos de GEOBIA para a classificação de uso e cobertura da terra na área de estudo.

3.1 Fotogrametria com VANTS por *Structure From Motion*

A fotogrametria é definida como a arte e ciência de realizar medições precisas por meio de fotografias aéreas (JENSEN, 2011). Para Tommaselli (2009) as câmeras utilizadas em fotogrametria são categorizadas em métricas e não métricas, sendo que a característica geométrica é a principal diferença entre estas. As câmeras métricas possuem sistema de lentes de alta qualidade geométrica, dispositivo de planura do filme (para câmeras analógicas) e marcas fiduciais (câmeras analógicas). As câmeras não métricas são de uso doméstico ou utilizadas por profissionais de fotografia, e não possuem exatidão geométrica ou dispositivos que garantam a obtenção de uma imagem fidedigna, podendo ser utilizadas para fotogrametria quando utilizadas com muitos pontos de apoio por fotografia além de ser necessária a calibração do sensor, para a verificação da estabilidade de seus componentes.

Jensen (2011) aborda que as câmeras digitais se diferenciam principalmente pelo sensor uni ou bidimensional, CCD (*Charge-Couple Device*) ou CMOS (*Complementary Metal Oxide Semiconductor*). Essas câmeras são classificadas de acordo com o tamanho do sensor, podendo ser câmeras digitais de pequeno, médio e de grande formato. No processo de aquisição de uma imagem por uma câmera digital, são adquiridas três imagens no momento da tomada da fotografia, correspondendo a três intervalos do espectro eletromagnético. Estas imagens correspondem ao comprimento de onda do verde, vermelho e azul. Ao final essas imagens são combinadas em uma única imagem, pela teoria aditiva de cores.

Estudos recentes têm mostrado a produção de informações a partir de imagens adquiridas por VANT como um elemento revolucionário para o monitoramento do meio

ambiente (AASEN *et al.*, 2018). Madawalagama *et al.* (2016) apontam que estas plataformas são uma alternativa aos sensores orbitais, sendo usados na captura de dados voltados para o mapeamento de alta resolução espacial e temporal. Fitzpatrick (2015) destaca que existem basicamente três vantagens no uso de veículos aéreos não tripulados: baixo custo de investimento inicial, baixo custo de mobilização e o menor tempo necessário para concluir a aquisição das imagens. Para Aasen *et al.* (2018) estas plataformas podem ser equipadas com uma variedade de sensores, destacando-se, câmeras de pequeno ou médio porte, sistemas de câmeras termais ou infravermelhas, câmeras multiespectrais, sensores hiperespectrais, LIDAR (*Light Detection and Ranging*), entre outros. Além disso, sensores mais simples, como as câmeras RGB e RGB modificadas (onde o filtro infravermelho é removido) também são utilizadas para capturar dados espectrais. Essas câmeras RGB tem como principal vantagem a sua alta resolução espacial e o custo relativamente baixo, tendo como principal limitação a sobreposição entre suas bandas espectrais (AASEN *et al.*, 2018).

O advento de plataformas VANT versáteis, de baixo custo e equipadas com câmeras de pequeno formato, aliado ao desenvolvimento de algoritmos de *Structure from Motion* (SfM), propiciaram novas maneiras de adquirir dados tridimensionais usando fotogrametria aérea (REMONDINO *et al.*, 2014). Esta abordagem demonstrou sua capacidade de gerar MDS com uma precisão comparável à das abordagens baseadas em LIDAR, porém com menor custo (WALLACE *et al.*, 2016).

O *Structure from Motion* (SfM) é uma técnica que possibilita a geração de nuvens de ponto tridimensionais e georreferenciadas de alta densidade e com custo reduzido se comparada a métodos tradicionais de levantamentos fotogramétricos. Além disso, também identifica, de maneira automatizada, características de correspondência nas regiões de sobreposição entre as fotografias e calcula automaticamente os parâmetros de localização, orientação e calibração de câmera. Pode-se, então, traçar um paralelo com a fotogrametria tradicional e o método de ajustamento por feixes de raios, conhecido também como *bundle block adjustment*, onde, de acordo com Brito e Coelho (2007), os parâmetros de orientação externa associados às coordenadas do espaço-objeto são determinados em apenas um ajustamento.

O SfM utiliza como base parâmetros determinados, gerando um modelo tridimensional prévio, que é representado por uma nuvem de pontos esparsa, posteriormente densificada com o uso da técnica *Multi-View Stereo* (MVS). Por essa razão, essa técnica é também denominada de SfM-MVS. A nuvem de pontos densa, na qual cada ponto possui uma posição tridimensional conhecida é a base para a geração do MDS, que é utilizado posteriormente no processo de ortorretificação das aerofotografias (RODRIGUES, 2018). Ressalta-se a importância do sistema proposto por Lowe (2004), denominado em inglês *Scale Invariant Feature Transform* (SIFT), que possibilita a localização automática de pontos de ligação ou fotogramétricos, conhecidos como *Tie Points* entre imagens consecutivas, estando presente nos principais softwares com a abordagem SfM-MVS.

Carrivick *et al.* (2016) aponta que estes recentes desenvolvimentos levam a assumir que o SfM-MVS representa o mais recente avanço na Fotogrametria, considerando que se trata de uma técnica que combina princípios fotogramétricos com evoluções em algoritmos de visão tridimensional, simplificando os processos e gerando economia de recursos. A qualidade dos trabalhos realizados por SfM-MVS está relacionada com diversos fatores, incluindo a câmera utilizada (MICHELETTI *et al.*, 2014), a quantidade e resolução espacial das imagens adquiridas, a distribuição das imagens, a distribuição e a qualidade dos pontos de controle no terreno (*Ground Control Points* - GCPs (JAMES e ROBSON, 2014), e o *software* de processamento (OUÉDRAOGO *et al.*, 2014).

3.2 Imagens de nanossatélites

Historicamente a coleta e o arquivamento de dados de observação da Terra têm sido liderados por agências governamentais. Isso gera uma série de benefícios, como a continuidade em algoritmos de processamento de dados e o acesso mais aberto e público aos dados (WULDER *et al.* 2012; ZHU *et al.* 2019). Uma desvantagem desse modelo tem sido os atrasos extremamente longos para desenvolver e lançar sistemas de satélite. Programas de satélite comerciais como Digital Globe, QuickBird e RapidEye reduziram os tempos de produção das plataformas, porém o processo de construção e lançamento ainda permaneceu lento (DAVIS e FILIP, 2015).

Empresas como a Planet (Planet Labs, Inc., San Francisco, CA, EUA) têm inovado a observação da Terra ao desenvolver satélites em miniatura, chamados de nanossatélites, que podem ser produzidos e lançados muito mais rápido do que os satélites tradicionais. Seu pequeno tamanho permite que sejam construídos rapidamente, e estes não requerem um veículo de lançamento dedicado, já que podem ser colocados em órbita como carga útil secundária (CRUSAN e GALICA, 2019).

As constelações de nanossatélites possuem um grande número de unidades sensoras pequenas, compactas e com baixo custo de produção (ESPER *et al.*, 2000). Nos últimos anos, a capacidade de imageamento de grandes porções da superfície e com alta frequência (diária), se aproximou da realidade operacional, com uma série de esforços comerciais explorando essa estratégia de observação (HOUBORG e MCCABE, 2016).

Os nanossatélites receberam esta denominação devido ao menor tamanho em relação aos microssatélites (SANDAU, 2010). Estes sensores apresentam peso entre 1 kg e 10 kg. Quando possuem formato cúbico de aproximadamente 10 cm, estes são denominados CubeSat (DUNBAR, 2019).

Utilizam-se os CubeSat em missões com diversas finalidades, nas quais há a demanda por imagens com alta resolução temporal, como a observação de tempestades, ciclones e furacões, medição de terremotos, detecção de propriedades de aerossol e nuvens, além de imageamento óptico de nuvens (BLACKWELL, CAHOY, ERICKSON, 2013; SELVA, KREJCI, 2012; SWARTWOUT, 2013). Como trata-se de uma tecnologia que apresenta baixo custo, diversos países realizaram lançamentos, possibilitando o aumento de missões e gerando uma maior diversificação dos dados de observação da Terra (SANDAU, 2010).

Além disso, o custo reduzido da produção e lançamento dos nanossatélites viabiliza a pesquisa a partir de dados gerados com sensores embarcados nessas plataformas. A companhia Planet foi pioneira no uso de nanossatélites com propósito comercial. Essa companhia opera com três constelações de observação da Terra: Skysat (5 satélites convencionais), RapidEye (5 microssatélites) e PlanetScope (mais de 175 nanossatélites) (TOTH e JÓZKÓW, 2016).

A constelação PlanetScope é a primeira das três gerações de nanossatélites projetadas para operar na órbita terrestre com diferentes sistemas ópticos. Em 2016 foram lançados os primeiros 12 nanossatélites CubeSat 3U dessa constelação (BAYLOR, 2018; PLANET, 2018a; PLANET 2018b). Possuindo massa de 4 kg, o nanossatélite CubeSat 3U tem dimensões de 10x10x30 cm, com capacidade de recobrir 150 x 106 km²/dia, possuindo um sensor de resolução de 11 megapixels, constituído por uma matriz de detectores do tipo CCD (PLANET, 2018a; EOPORTAL, 2018). Esses sensores podem gerar imagens diárias da superfície terrestre, a partir de órbitas quase-polar heliosíncronas, a cerca de 475 km de altitude, dispondo de quatro bandas espectrais: três bandas no visível e uma no infravermelho próximo (*Near Infrared* - NIR), adicionada a partir de um filtro de divisão de quadro como demonstrado na (Tabela 1) (PLANET, 2018a).

Tabela 1 - Características do CubeSat 3U e de seu sensor multiespectral

| | | |
|---|-------------------------------------|---------|
| Altitude da Órbita (Referência) | 475 km (~98° de inclinação) | |
| Max/Min Latitude | ± 81,5° | |
| Horário de Passagem na Linha do Equador | 9:30-11:30 am (Horário Solar Local) | |
| Bandas Espectrais (nm) | R | 590-670 |
| | G | 500-590 |
| | B | 455-515 |
| | NIR | 780-860 |
| Tamanho do Quadro (km) | 24,6 x 16,4 | |
| Tempo de Revisita | Diário no Nadir | |
| Alcance Dinâmico da Câmera (bit) | 12 | |

Fonte: Adaptado de PLANET (2018a).

As correções radiométricas e geométricas dessas imagens viabilizam a geração de produtos em diferentes níveis de processamento: *PlanetScope Basic Scene*, *PlanetScope Ortho Scene* e *PlanetScope Ortho* (Tabela 2).

Tabela 2 - Características dos Produtos PlanetScope

| Nível | | 1B | 3B | 3A |
|-------------------------------|-----------------|---|--|--|
| Descrição | | Correção radiométrica e no sensor, dimensionado para radiância ao topo da atmosfera - TOA, sem projeção cartográfica e baseado em cena para usuários com recursos avançados de processamento de imagens e correção geométrica | Ortorretificado, dimensionado para TOA, adequado para uso analítico e visual, baseado em cena e com projeção cartográfica. | Correção radiométrica e do sensor, ortorretificado e com projeção cartográfica em UTM. |
| Resolução Espacial (m) | Solo | 3,7 | - | 3,7 |
| | Ortorretificado | - | 3,125 | 3,125 |
| Resolução Radiométrica (bits) | Visual | - | 8 | 8 |
| | Analítico | 12 | 12 | - |
| | | 16 | 16 | - |
| Resolução Espectral | Visual | - | RGB | |
| | Analítico | RGB+NIR | | |

Fonte: Adaptado de PLANET (2018a)

Os produtos PlanetScope níveis 3A e 3B passam por processos de ortorretificação, que consistem em correções das distorções da imagem causadas pelo terreno, a partir de coeficientes polinomiais racionais e de MDS de diferentes fontes. A precisão planimétrica para estes produtos em 80% dos casos é melhor do que 7 m (PLANET, 2018a).

A precisão radiométrica de calibração dessas imagens é de 5%, medida em laboratório. As imagens possuem resolução radiométrica original de 12 bits e após a realização de processamentos e correção radiométrica são escalonadas para 16 bits. Os Números Digitais, do inglês, *digital number* (DN), são escalonados para 0,01 W/(m²*sr*µm), para minimizar os erros de quantização, representando os valores absolutos de radiância calibrada. Para converter os DN em radiância (Equação 1) para os produtos analíticos, é necessário a aplicação do fator de escala radiométrico, do inglês, *radiometric scale factor* (RSF), nos Números Digitais (PLANET, 2018a).

$$RAD(i) = DN(i) \times RSF(i) \quad (1)$$

Onde $RSF(i)$ é o fator de escala radiométrico, com valor de 0,01. Os valores resultantes são de radiância no sensor para cada pixel, expresso em Watts por metro quadrado por estereoradiano ($W/m^2 \cdot sr \cdot \mu m$) (PLANET, 2018a).

A conversão dos produtos analíticos para reflectância ao topo da atmosfera (*Top of Atmosphere* - TOA) (Equação 2) é feita utilizando valores do coeficiente de reflectância calibrada ($RC(i)$), encontrados no arquivo .xml nos DN (PLANET, 2018a).

$$REF(i) = DN(i) \times RC(i) \quad (2)$$

A partir da utilização da imagem com reflectância corrigida para TOA é realizada a correção desses dados para reflectância superficial (*Bottom of Atmosphere* - BOA). Para o cálculo da reflectância BOA, pixel a pixel, é empregado o modelo de transferência radiativa 6S, denominando em inglês *Second Simulation of the Satellite Signal in the Solar Spectrum (6S)*, separadamente para cada sensor da constelação PlanetScope. Ainda são utilizados produtos MODIS NRT (*Moderate Resolution Imaging Spectroradiometer - Near Real-Time Global Flood*) de vapor de água e de ozônio. Os resultados desta correção são altamente correlacionados com os dados Landsat 8, quando utilizados em análise temporal com uso de índices de vegetação (PLANET, 2018c).

3.3 Métodos de fusão de imagens

A aquisição de imagens de alta resolução espacial e espectral tem aumentado consideravelmente ao longo dos últimos anos. O objetivo das técnicas de fusão de imagens é a combinação de dados com a finalidade de se obter uma melhora na detecção e discriminação de alvos. No sensoriamento remoto aplicado à superfície terrestre, de forma geral combinam-se imagens com diferentes resoluções espacial e espectral, obtidas por diferentes sensores ou até mesmo por sensores ativos e passivos (WALD, 2002). Entre os métodos de fusão, destacam-se a Transformação IHS, Análise de Componentes Principais, Transformação Wavelet, P+XS e Brovey.

De acordo com Dhore e Veena (2015) a transformação IHS (*Intensity-Hue-Saturation*) é o método de fusão de imagens mais comum para aplicações em sensoriamento remoto, sendo muito utilizado em softwares comerciais. Essa técnica

converte as cores primárias RGB para o espaço de cores IHS. O componente de intensidade (brilho da imagem) é substituído pela imagem da banda pancromática (PAN), ao passo que os componentes *Hue* (matiz) e *Saturation* (saturação) são reamostrados para a mesma resolução espacial da banda PAN e posteriormente a imagem fusionada PAN-HS é convertida para o espaço de cores RGB.

A fusão por Análise de Componentes Principais (*Principal Component Analysis* - PCA) é semelhante ao método IHS, contudo, pode ser aplicado a um número maior de bandas (WALD, 2002). Nesse método o primeiro passo é o cálculo das componentes principais da imagem multiespectral e, em seguida, a primeira componente principal, contendo a maior parte da variância do conjunto de dados, é substituída pela imagem PAN, após uma adaptação do respectivo histograma. Por último, a nova versão das componentes principais é convertida de volta ao espaço de cores RGB inicial (CAO *et al.*, 2003). De acordo com Dhore e Veena (2015) os métodos de fusão IHS e PCA apresentam melhores resultados espaciais, preservando melhor a forma das feições.

Dhore e Veena (2015) abordam que a transformação *Wavelet* trata-se de um método em que a imagem é decomposta em componentes de acordo com a sua frequência. Este método faz uma transformação *Wavelet* na imagem multiespectral para extrair dados de baixa frequência, com os dados PAN sendo utilizados para representar dados de alta frequência. Os coeficientes desses dados extraídos são combinados para produzir a imagem fusionada por *Wavelet*, obtido através de uma transformação inversa que origina a imagem final.

Outro método abordado pelos autores é o P+XS, no qual a imagem PAN é realçada por meio de um filtro passa-alta, de detecção de bordas. A imagem PAN é gerada por combinação linear de bandas multiespectrais (XS) para obter a informação espectral dos dados (DHORE; VEENA, 2015).

O método Brovey pode ser aplicado para até três bandas espectrais. Produz três novas bandas com maior resolução espacial: as bandas da imagem fusionada são calculadas a partir da normalização de cada uma das bandas da imagem multiespectral original e multiplicadas pela imagem pancromática (TEMING *et. al.*, 2005).

3.4 Análise de imagens baseada em objetos geográficos

Os sensores de altíssima resolução espacial modificaram o sensoriamento remoto nas últimas décadas, tornando necessários novos métodos de interpretação e classificação de imagens (BLASCHKE e KUX, 2007). Uma vez que os dados de sensores remotos apresentavam pixels em tamanhos comumente maiores ou semelhantes aos objetos de interesse a abordagem das classificações era voltada para o pixel ou mesmo para o subpixel (HAY e CASTILLA, 2008). Contudo, como a evolução na resolução espacial das imagens, passou-se a uma abordagem voltada para a derivação de objetos compostos por grupos de pixels, a análise baseada em objetos geográficos (BLASCHKE, 2010).

A análise de imagens baseada em objetos geográficos (GEOBIA, do inglês: *Geographic Object Image Analysis*), consiste em um sistema de reconhecimento de padrões, que permite classificar uma série de dados tabulares, gerados a partir de objetos vetoriais produzidos por técnicas de segmentação, por meio da identificação da heterogeneidade espacial (índices de forma, compacidade e suavidade), da heterogeneidade espectral (cor) e da diferença dos objetos de entorno e escala (tamanho dos objetos) Freitas (2013) e Powers *et al.* (2015). A abordagem GEOBIA consiste basicamente em duas etapas metodológicas: a segmentação e a classificação da imagem.

A segmentação compreende a etapa na qual os pixels homogêneos e contíguos são identificados e agrupados em objetos geográficos (BLASCHKE *et al.*, 2014; YU *et al.*, 2006). Esse agrupamento gera objetos com padrões internos que contrastam com os de sua vizinhança. Tal procedimento pode ser feito em diferentes escalas, por meio da segmentação multinível ou multirresolução, implementada em softwares de processamento digital de imagens (PDI). Cada escala apresenta um nível de objetos e a conexão desses níveis ocorre de forma hierárquica (TEDESCO, ANTUNES E OLIANI, 2014). Assim pode-se dizer que a GEOBIA tem como base o agrupamento de pixels gerados a partir da segmentação, sendo importante ressaltar que quanto melhor for executado este processo, melhor será o desempenho da classificação dos mesmos (YAN *et al.* 2006).

Para Antunes *et al.* (2014), a avaliação das características das imagens é necessária para a definição de qual técnica de segmentação será adotada para produzir um melhor resultado para a classificação de uso e cobertura da terra. Por fim, pode-se combinar a informação espectral com a forma dos objetos e características de textura para melhorar esse processo (BAATZ e SCHAPE, 2000).

A classificação consiste em agrupar objetos ou segmentos que apresentam características similares. Como resultado se obtém um mapa com as informações temáticas da região, mostrando a distribuição geográfica das classes (BLASCHE e KUX, 2007).

Um tradicional classificador aplicado a dados de sensoriamento remoto é o da máxima verossimilhança (MaxVer). De acordo com Myburgh e Niekerk (2013), esse classificador quantifica as médias e as matrizes de covariâncias das amostras das classes a partir desses valores e dos valores das regiões a serem classificadas, determinando a probabilidade de um segmento ou objeto pertencer a uma determinada classe. Os autores apontam que a probabilidade é calculada pela Função de Densidade Probabilística, a qual supõe que os atributos preditores seguem uma distribuição normal.

Algumas barreiras para essa abordagem são que alguns atributos não são representados apenas por medidas estatísticas: estes não apresentam distribuição normal em relação às classes. Outra dificuldade é a quantidade de atributos gerados na classificação por regiões, pois além de valores médios das bandas são utilizados atributos geométricos. Em uma análise do classificador MaxVer para a classificação de regiões, Myburgh e Niekerk (2013) concluíram que o aumento do número de atributos preditores diminui o desempenho do classificador.

Nesse sentido foram desenvolvidos trabalhos como os de Chutia *et al.* (2014) e Fernandes *et al.* (2014), para reduzir a dimensionalidade dos dados e dos algoritmos de classificação não paramétricos utilizando técnicas de mineração de dados. Hand *et al.* (2001) abordam que a mineração de dados pode ser entendida como uma área do conhecimento que abrange as técnicas de reconhecimento de padrões, estatística, banco de dados e de visualização, realizando a extração de informações de grandes conjuntos de dados. Os métodos de classificação no processo de mineração de dados

são considerados não paramétricos e os mais utilizados são o *K-Nearest Neighbor* (KNN) o *Support Vector Machine* (SVM) e Árvores de Decisão (AD).

De acordo com Altaman (1992), o *K-Nearest Neighbor* (kNN) é um método de classificação não paramétrico que atribui à um objeto a classe mais frequente entre um número 'k' de amostras de classes de interesse próximos a ele. Miranda *et al.* (2020) apontam que cada objeto é selecionado por uma maioria de votos de seus vizinhos, sendo que a classe mais comum de seus 'k' vizinhos mais próximos é atribuída ao objeto: essa proximidade é definida em termos da distância euclidiana das variáveis com os eixos do espaço de atributos.

Mountrakis *et al.* (2011) abordam que o *Support Vector Machine* (SVM) é uma técnica de aprendizagem estatística não paramétrica que, a partir de amostras de treinamento, visa encontrar um hiperplano que separa o conjunto de dados em um número pré-definido de classes diferentes. Nele, o hiperplano é criado por meio de um espaço espectral n-dimensional que separa as classes com base em uma função de kernel e em parâmetros otimizados por aprendizado de máquina para melhorar a margem do ponto mais próximo ao hiperplano. O SVM é um método que pode manipular dados de distribuições estatísticas desconhecidas e pequenos conjuntos de dados de treinamento (VAPNIK, 2013).

Para Castanheira (2009), as técnicas de árvore de decisão, em inglês *Decision Tree* (DT), são utilizadas em problemas de classificação e regressão, elas particionam recursivamente um conjunto de treinamento, até que cada subconjunto resultante apresente casos de uma única classe. A construção da árvore de decisão é fundamentada no modelo *Top-Down*, isto é, a sua estrutura inicia no nó raiz e vai até as suas folhas. Ainda segundo esta autora, apesar dos algoritmos desse grupo conterem diferenças, os algoritmos de árvore de decisão tentam descobrir maneiras de dividir sucessivamente o conjunto em vários subconjuntos, até que cada um apresente apenas uma classe ou que uma das classes seja a maioria, não sendo necessário realizar novas divisões.

O *Boosted C5.0* é um algoritmo baseado em árvore de decisão, sendo uma evolução do algoritmo C.4.5. A principal diferença em relação ao seu antecessor foi a incorporação de um método de reforço (*boosting*) na determinação do modelo resultante, além de uma abordagem para seleção de atributos mais informativos na

construção das árvores, denominado *winnnow*. O ganho de informação normalizado é o critério para esta divisão, atribuindo um peso a cada amostra; quanto maior o peso maior será a influência da amostra na árvore de decisão (RUIZ, 2015; KUHN e QUINLAN, 2021).

O método *Random Forest* foi desenvolvido por Breiman (2001). O termo floresta aleatória é utilizado pois a técnica cria uma combinação de árvores de decisão para atingir uma predição com maior acurácia e estabilidade. Nesta técnica, as árvores são treinadas com os mesmos recursos, mas em conjuntos de treinamento diferentes. Cada árvore contribui com um voto para a atribuição de classe de um objeto. Assim, a classe mais votada pelo conjunto de árvores é assinalada ao objeto (BREIMAN, 2001; BELGIU e DRĂGUȚ, 2016).

Em particular, o *Random Forest* é apropriado para calcular a função não linear de variáveis e pode refletir a interação entre variáveis (Liu *et al.*, 2019). Como cada árvore usa apenas uma parte das variáveis de entrada, o algoritmo é consideravelmente mais leve do que classificadores convencionais comparáveis (GISLASON *et al.*, 2006). Por este motivo, o RF é considerado um dos melhores algoritmos de classificação, pois possui uma elevada precisão na classificação de um grande conjunto de dados (WALKER, 2013).

De acordo com Mota (2019), de maneira geral, os métodos que utilizam a lógica de DT apresentam um baixo viés, mas elevada variância, isso acaba por produzir um sobreajuste. Este fato se caracteriza quando o método apresenta uma grande performance no conjunto de dados em que foi treinado, porém piora significativamente quando se aplica ao conjunto de dados a ser classificado, apresentando dificuldades de generalização das classes. No entanto, a utilização do *Random Forest* trata o problema da variância ao gerar várias árvores, e aplicar uma lógica de produzir informações independentes em cada nó final dessas árvores, reduzindo assim a variância por meio da média desses resultados, uma vez que a variância individual de cada árvore é maior do que a variância da média das árvores.

Prentice *et al.* (2021), em um estudo para a classificação de espécies vegetais em zonas costeiras, utilizando imagens adquiridas por câmeras multiespectrais, apontaram que os algoritmos de RF têm desempenho superior à classificação gerada pelo algoritmo *K-Nearest Neighbor*.

Uma abordagem que integrou GEOBIA com DT foi utilizada por Hamedianfar *et al.* (2014), classificando imagens hiperespectrais e chegando a valores de acurácia global superiores a 90%. Esses autores também apontam que a classificação por DT aumentou a produtividade da GEOBIA. As árvores de decisão apresentam vantagens em relação a outras técnicas de mineração de dados, sendo processos de fácil interpretação dos seus resultados e que apresentam baixo tempo para realizar a construção do modelo (FRIEDL e BRODLEY, 1997).

3.5 Avaliação da acurácia da classificação

O emprego de critérios para avaliação e comparação da exatidão de mapeamentos temáticos foi descrito por Congalton (1991). Segundo este autor, uma matriz de confusão (Tabela 3) pode ser usada como o ponto de partida para a aplicação de uma série de técnicas estatísticas descritivas e analíticas.

Tabela 3 - Exemplo de matriz de confusão

| Classificação | Classe 1 | Classe 2 | ... | Classe K | Total |
|----------------------|-----------------|-----------------|------------|-----------------|--------------|
| Classe 1 | P_{11} | P_{12} | ... | P_{1k} | P_{1+} |
| Classe 2 | P_{12} | P_{22} | ... | P_{2k} | P_{2+} |
| ... | ... | ... | ... | | |
| Classe K | P_{k1} | P_{k2} | ... | P_{kk} | P_{k+} |
| Total | P_{+2} | P_{+2} | ... | P_{+k} | |

Baseando-se na matriz de confusão ou erro pode-se calcular uma série de medidas estatísticas, que concluem o processo de validação de Congalton (1991). Entre estas, a exatidão global (EG) é a medida mais simples e relaciona os elementos da diagonal principal da matriz de erro com o total de pontos amostrados, sendo dada pela Equação 3:

$$E_G = \frac{\sum P_{ii}}{n} \quad (3)$$

Onde:

E_G = exatidão global;

P_{ii} = elementos na diagonal principal da matriz de erro;

n = total de elementos amostrados.

Em uma análise mais rigorosa, deve-se levar em consideração os valores nas células marginais da matriz de erro. No caso das linhas da tabela 3, os valores indicam o número de amostras que, pertencendo a uma determinada categoria, não foram incluídos na mesma, sendo chamados de erros de omissão. Esses erros são calculados pela Equação 4:

$$E_o = \frac{P_{i+} - P_{ii}}{P_{i+}} \quad (4)$$

Onde:

E_o = erros de omissão;

P_{i+} = é a soma da linha i ;

P_{ii} = é o valor da coluna i e linha i .

De forma análoga as células nas diagonais das colunas expressam os erros de comissão (Equação 5), isto é, pixels que não se incluem em uma determinada categoria, sendo pertencentes realmente à outra:

$$E_{co} = \frac{P_{+i} - P_{ii}}{P_{+i}} \quad (5)$$

Onde:

E_{co} = erros de comissão;

P_{+i} = é a soma da coluna i ,

P_{ii} = é o valor da coluna i e linha i .

Ressalta-se a importância do índice Kappa (IK) (Equação 6) na incorporação dos segmentos mal classificados junto com os bem classificados como a exatidão global (TEDESCO, ANTUNES, OLIANI, 2014). Os valores da estatística Kappa variam entre zero e um indicando a qualidade da classificação, sendo que: valores entre 0,8 e 1,0, indicam uma classificação excelente; entre 0,6 e 0,8, muito boa; entre 0,4 e 0,6, boa; entre 0,2 e 0,4, razoável; ente 0 e 0,2, ruim; e abaixo de 0, considera-se péssima (LANDIS; KOCH, 1977). O resultado mais importante para a discussão é a análise da matriz de confusão resultante destes processos (PONTIUS e MILLONES, 2011).

$$k = \frac{n \sum_i^k P_{ii} - \sum_i^k P_{i+} P_{+i}}{n^2 - \sum_i^k P_{i+} P_{+i}} \quad (6)$$

Onde:

n = número total de amostras;

c = número total de classes;

x_{i+} = soma da linha i ;

x_{+i} = soma da coluna i da matriz de confusão;

x_{ii} = valor da coluna i e linha i .

4 PROCEDIMENTOS METODOLÓGICOS

Neste capítulo estão descritas características da área de estudo, bem como os materiais e métodos utilizados na aquisição e no processamento fotogramétrico, na aquisição das imagens de nanossatélites, além dos processos de fusão, segmentação e classificação das imagens. Essas etapas podem ser visualizadas no fluxograma da Figura 1.

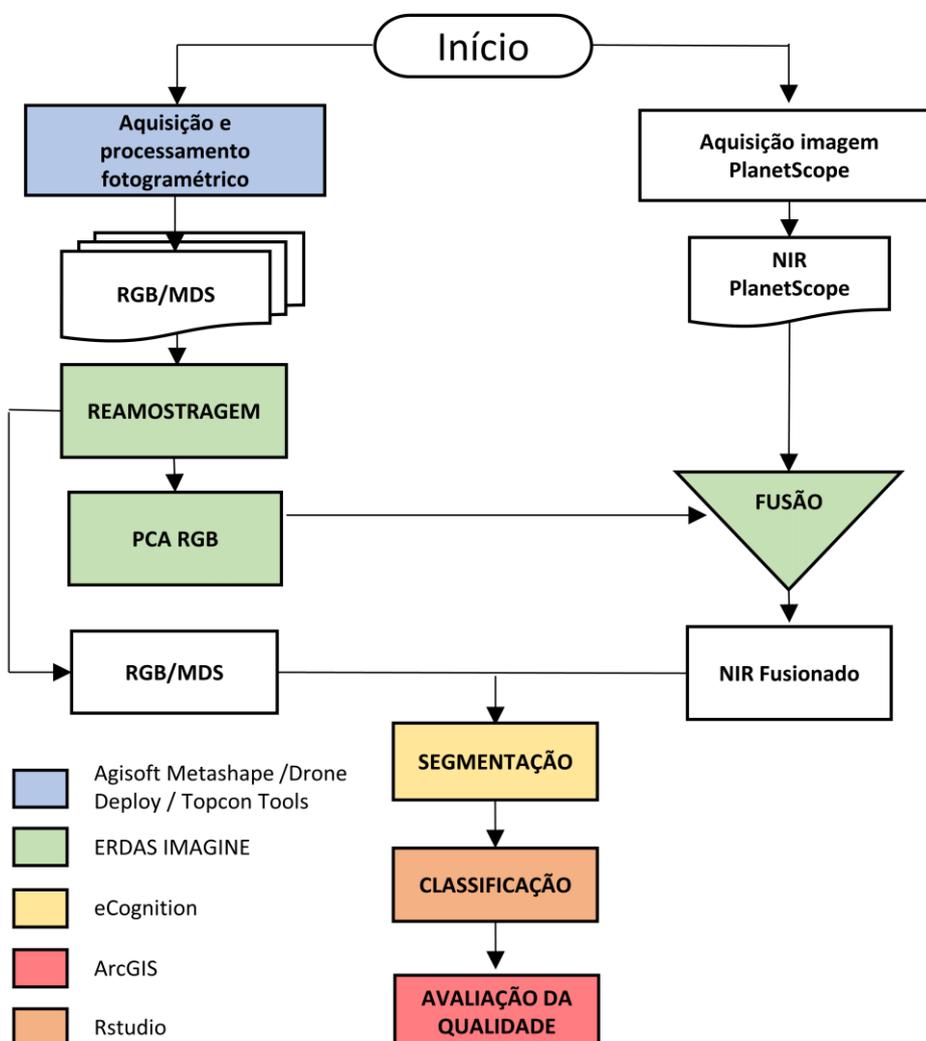


Figura 1 - Fluxograma metodológico

4.1 Localização e caracterização da área de estudo

A Estação Experimental Agronômica da Universidade Federal do Rio Grande do Sul (EEA/UFRGS) está localizada no município de Eldorado do Sul (Figura 2) e abrange uma área total de aproximadamente 1.560 hectares, onde são desenvolvidas diversas atividades de ensino e pesquisa.

Neste estudo foi escolhida uma área de aproximadamente 160 hectares, situada na porção sul da EEA/UFRGS, que apresenta diferentes classes de uso e cobertura da terra, tais como áreas de fruticultura, pastagem, cultivos, mata nativa, estradas, corpos d'água e edificações.

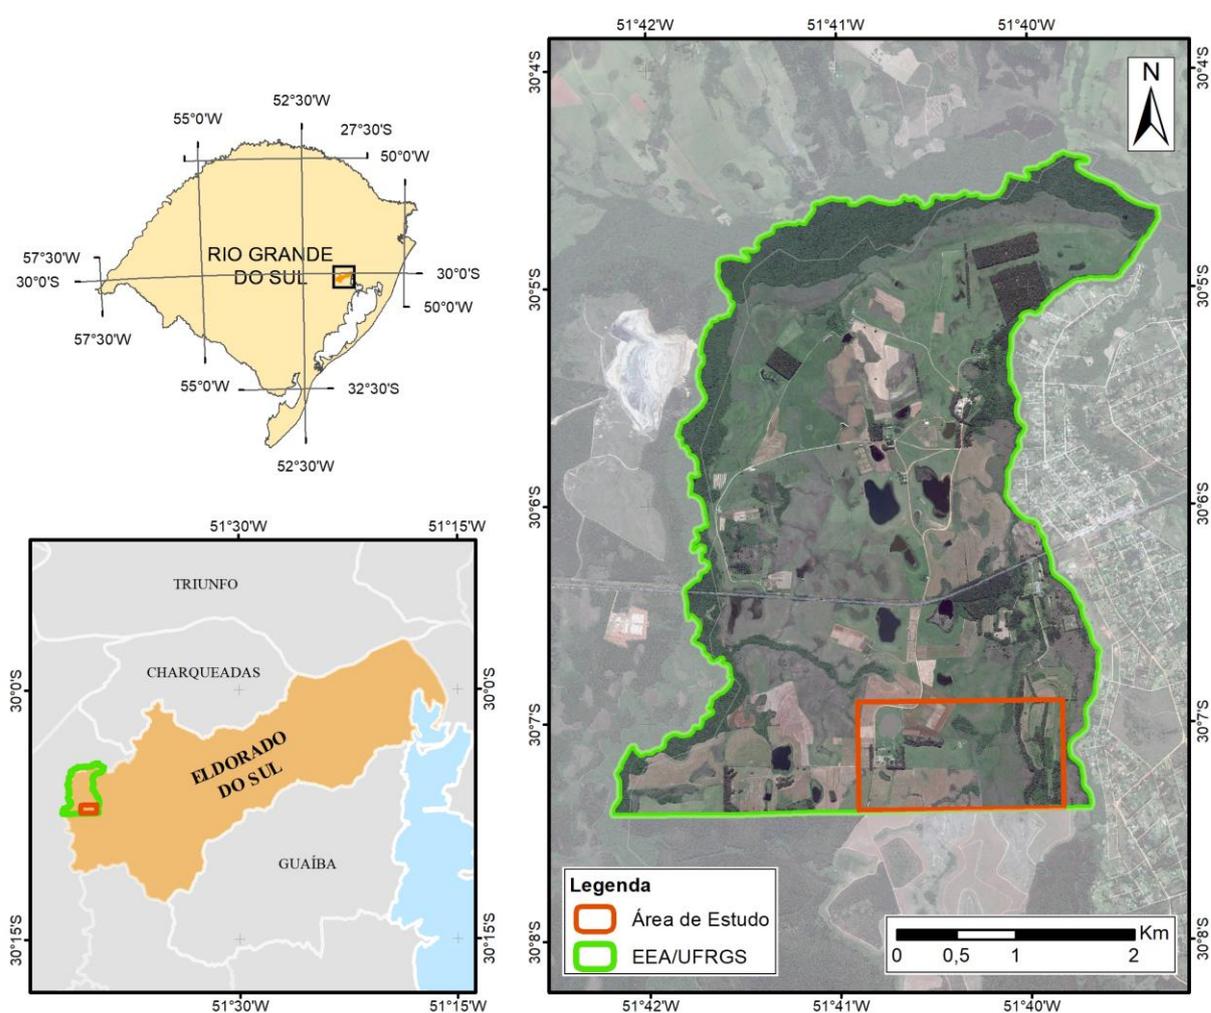


Figura 2 - Localização da área de estudo sobre composição colorida RGB 321 de imagem do nanossatélite PlanetScope, obtida em 06/09/2018.

4.2 Plataformas e sensores utilizados

Nesta pesquisa foram utilizadas imagens adquiridas por câmera fotográfica embarcada em VANT e imagens de sensor multiespectral de nanossatélite da constelação PlanetScope. Para tanto, foram empregados seguintes materiais:

- i) DJI Phantom 3, para realização de levantamento fotogramétrico;
- ii) Par de receptores do Sistema Global de Navegação por Satélite, (Global Navigation Satellite System - GNSS) Topcon Hiper+ (L1/L2) e software TOPCON TOOLS, para definição das coordenadas dos pontos de apoio pré-sinalizados.
- iii) Programa Agisoft Metashape 1.5.2, para o processamento fotogramétrico (Orientação interna, Orientação externa, geração de MDS e de Ortofotomosaico);
- iv) Programa ERDAS IMAGINE 15 (Hexagon Geospatial), para a fusão das imagens;
- v) Programa eCognition 9.0.1 (Trimble), para a segmentação dos ortofotomosaicos;
- vi) Interface gráfica Planet, para o download das imagens de nanossatélite;
- vii) Produtos PlanetScope de reflectância superficial;
- viii) RStudio v.1.1.4.1106, para implementação dos algoritmos C5.0 e *Random Forest*; e
- ix) Programa ArcGIS 10.5 (ESRI, Inc), para a visualização dos dados em ambiente de sistema de informações geográficas, elaboração dos mapas temáticos e processamento dos dados.

Na aquisição das imagens utilizou-se um VANT multirrotor, modelo *Phantom 3 Advanced*, fabricado pela empresa DJI (Figura 3). Esse equipamento é capaz de realizar voos com velocidade de até 15 m/s e possui um sistema de navegação composto por sistema inercial, acelerômetros, giroscópio eletrônico, barômetro e receptor GNSS. A aeronave dispõe de uma câmera fotográfica compacta, não calibrada, montada sobre um estabilizador de três eixos e um sensor do tipo CMOS de 1/2.3", que pode obter imagens de 4000 x 3000 pixels (12,4 megapixels). Outras

características desta câmera são sua lente com distância focal de 20mm equivalente a 35mm, com um ângulo de visão de 94° (RODRIGUES, 2018).



Figura 3 - DJI Phantom 3 Advanced

Para o levantamento geodésico foi utilizado um par de receptores GNSS *Hiper Lite+* de dupla frequência (Figura 4). As características desses equipamentos envolvem a precisão horizontal de até 3 mm + 0,5 ppm e vertical de 5 mm + 0,5 PPM, estrutura de alumínio e à prova d'água, com bateria de autonomia para até 16 horas.



Figura 4 - Receptor GNSS Hiper Lite+

4.3 Levantamento aerofotogramétrico com VANT

O levantamento aerofotogramétrico compreende os procedimentos de planejamento das atividades, de aquisição dos dados em campo (fotografias aéreas acoplada a um VANT e levantamento geodésico dos alvos no terreno) e também o processamento desses dados, a figura 5 mostra as etapas de execução do levantamento fotogramétrico.

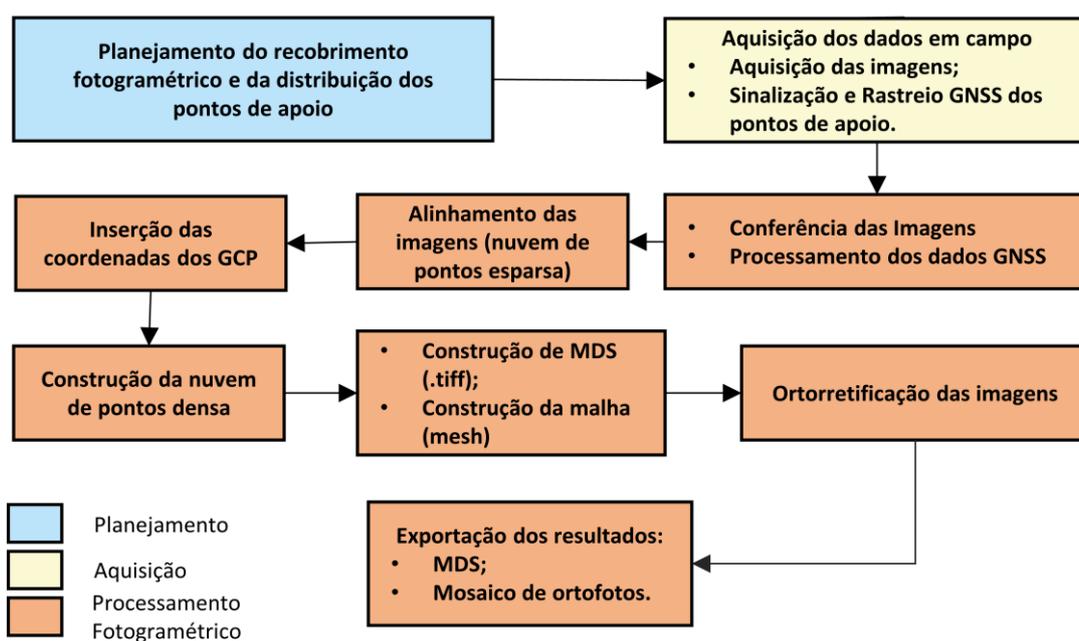


Figura 5 - Etapas do levantamento fotogramétrico

4.3.1 Planejamento

O planejamento envolveu a elaboração do plano de voo e da distribuição dos pontos de apoio no terreno (*Ground Control Points – GCP*), além da análise das características do local, avaliando possíveis fatores de risco para a sua realização e quais os melhores locais para realização de decolagem e acompanhamento da aquisição das imagens. Considerou-se a área mapeada e a resolução espacial das fotografias, a fim de determinar a altura de sobrevoo e das sobreposições lateral e

longitudinal entre as imagens. Assim, definiu-se a distribuição dos alvos pré-sinalizados no terreno, totalizando oito GCP, como demonstrado na Figura 6

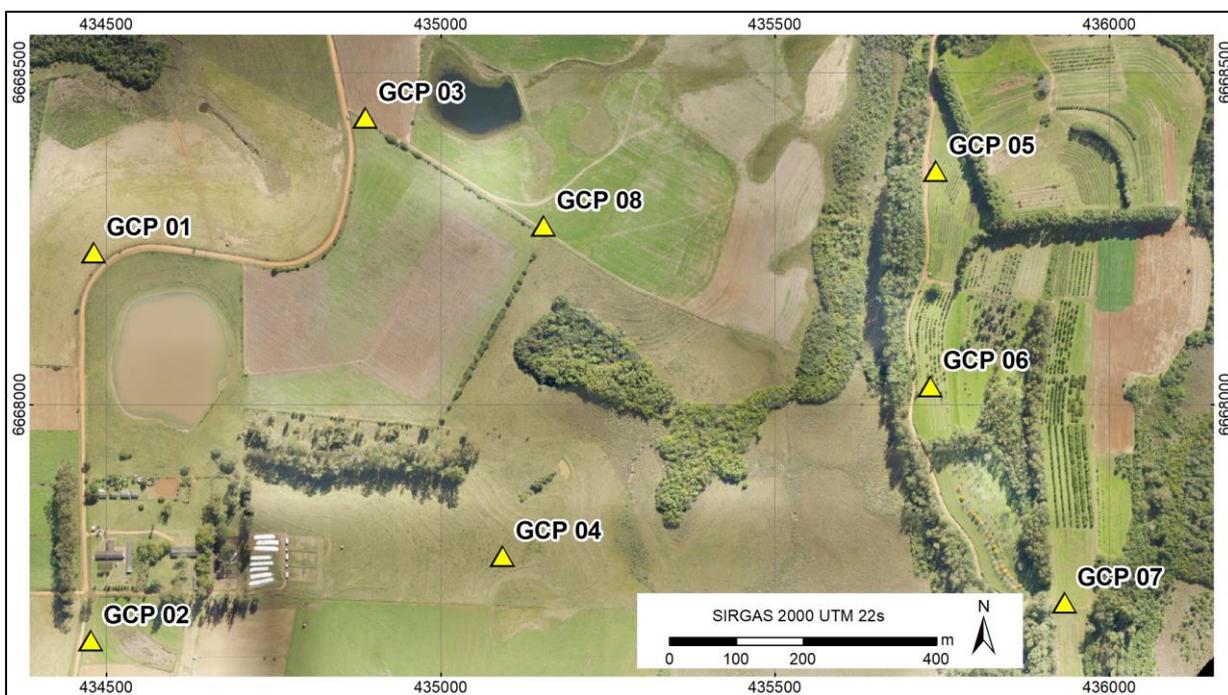


Figura 6 - Localização dos GCP na área de estudo

Para se obter imagens com resolução espacial no terreno (*Ground Sample Distance* - GSD) de 8 centímetros a altura de voo planejada foi de 120 m, com sobreposição longitudinal de 80% e lateral de 75%. A Figura 7 apresenta a interface do planejamento das missões executadas no local.

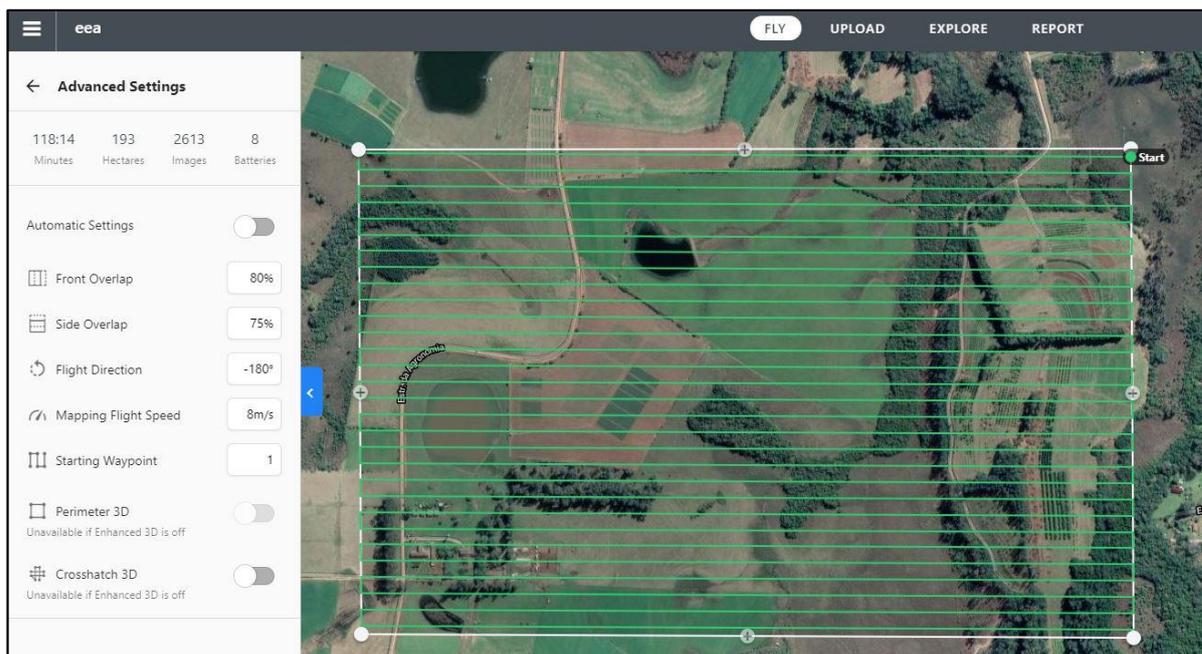


Figura 7 - Plano de voo no aplicativo Drone Deploy

4.3.2 Aquisição dos dados em campo

O trabalho de campo teve início com a sinalização e rastreamento dos pontos de apoio, que servem como referência para o aerolevante. Essa pré-sinalização foi realizada com a implantação de alvos de tecido que possuem a dimensão de 1 x 1 m, e com a posterior determinação das coordenadas do centro desses alvos por meio de rastreamento GNSS.

No rastreamento das coordenadas dos GCP aplicou-se o método de posicionamento relativo estático rápido, com o emprego de dois receptores simultaneamente (Topcon Hiper+ L1/L2) para definição das coordenadas dos alvos, mantendo-se um receptor fixo denominado de base e outro móvel para se obter as coordenadas dos pontos de interesse.

A conversão das altitudes geométricas em ortométricas foi realizada considerando o modelo de ondulação geoidal MapGeo 2015, disponibilizado pelo Instituto Brasileiro de Geografia e Estatística. Os resultados obtidos no software TOPCON TOOLS, estão descritos no Anexo I.

Depois da materialização e ocupação dos alvos por cerca de 10 min, foram executados os planos de voo, aproximadamente às 11h da manhã do horário local, no dia 09 de junho de 2018. Antes da decolagem verificou-se as condições da aeronave, foi feita a revisão de baterias, inspeção das hélices, calibração de bússola e sistema inercial e verificação do número de satélites GNSS para orientação do equipamento. Além disso procedeu-se a uma última revisão dos parâmetros de aquisição das imagens e observação das condições meteorológicas locais, além de possíveis obstáculos para a operação da aeronave e também a velocidade do vento. Após todas essas conferências foram executadas as missões, cada uma teve duração de aproximadamente 15 minutos, em conformidade com o tempo de autonomia da bateria, sendo necessário realizar três decolagens para o recobrimento da área.

4.3.3 Processamento Fotogramétrico

O processamento fotogramétrico foi efetuado no programa Agisoft Metashape, cumprindo o fluxo de trabalho que abrange o alinhamento das imagens, a inserção das coordenadas dos GCP, a densificação da nuvem de pontos, a construção de Rede Triangular Irregular (*Triangular Irregular Network* - TIN), a geração do MDS e a ortorretificação das imagens.

Inicialmente realiza-se o alinhamento das imagens, através de algoritmos SIFT, que identificam pontos homólogos entre as fotografias, determinando a posição das câmeras e a calibração da lente da câmera. O resultado desse processo é uma nuvem de pontos esparsa e um ajustamento inicial da posição de tomada das imagens vinculadas ao sistema de posicionamento do VANT. Após a realização do alinhamento, efetiva-se a inserção das coordenadas dos GCP pela importação das coordenadas obtidas pelo posicionamento geodésico dos alvos a partir de receptor GNSS de dupla frequência, vinculando o valor das coordenadas à sua posição no sistema da imagem. Esse procedimento é feito de forma manual, sendo imprescindível para garantir a qualidade do produto final. Os relatórios de processamento das imagens fotográficas do aerolevante executado podem ser acessados no Anexo II.

A partir das informações das posições das câmeras foi possível processar a construção da nuvem densa, gerando informações tridimensionais mais detalhadas da área de estudo. Este dado serve como base para a geração do MDS em formato *raster* e para a construção de malha (*mesh*) do terreno (interpolada pelo método TIN).

Cumpridas as etapas anteriores, passou-se para a produção das informações finais, sendo elas o MDS (Figura 8) e o mosaico de ortofotos (Figura 9). O MDS utilizado é a representação da superfície do local em formato *raster*, sendo calculado a partir da nuvem de pontos densa. Seguindo, efetivou-se a geração do ortofotomosaico, no qual as imagens originais tiveram suas distorções corrigidas com base na posição de tomada das imagens e nas informações de representação da superfície representadas na TIN. O mosaico de ortofotos e o MDS da área de estudo foram exportados no formato Geotiff, com projeção UTM 22s e datum SIRGAS 2000. Por fim, uma máscara vetorial da área de estudo foi digitalizada para que os produtos finais fossem recortados, eliminando as distorções presentes nas bordas do ortofotomosaico e do MDS.

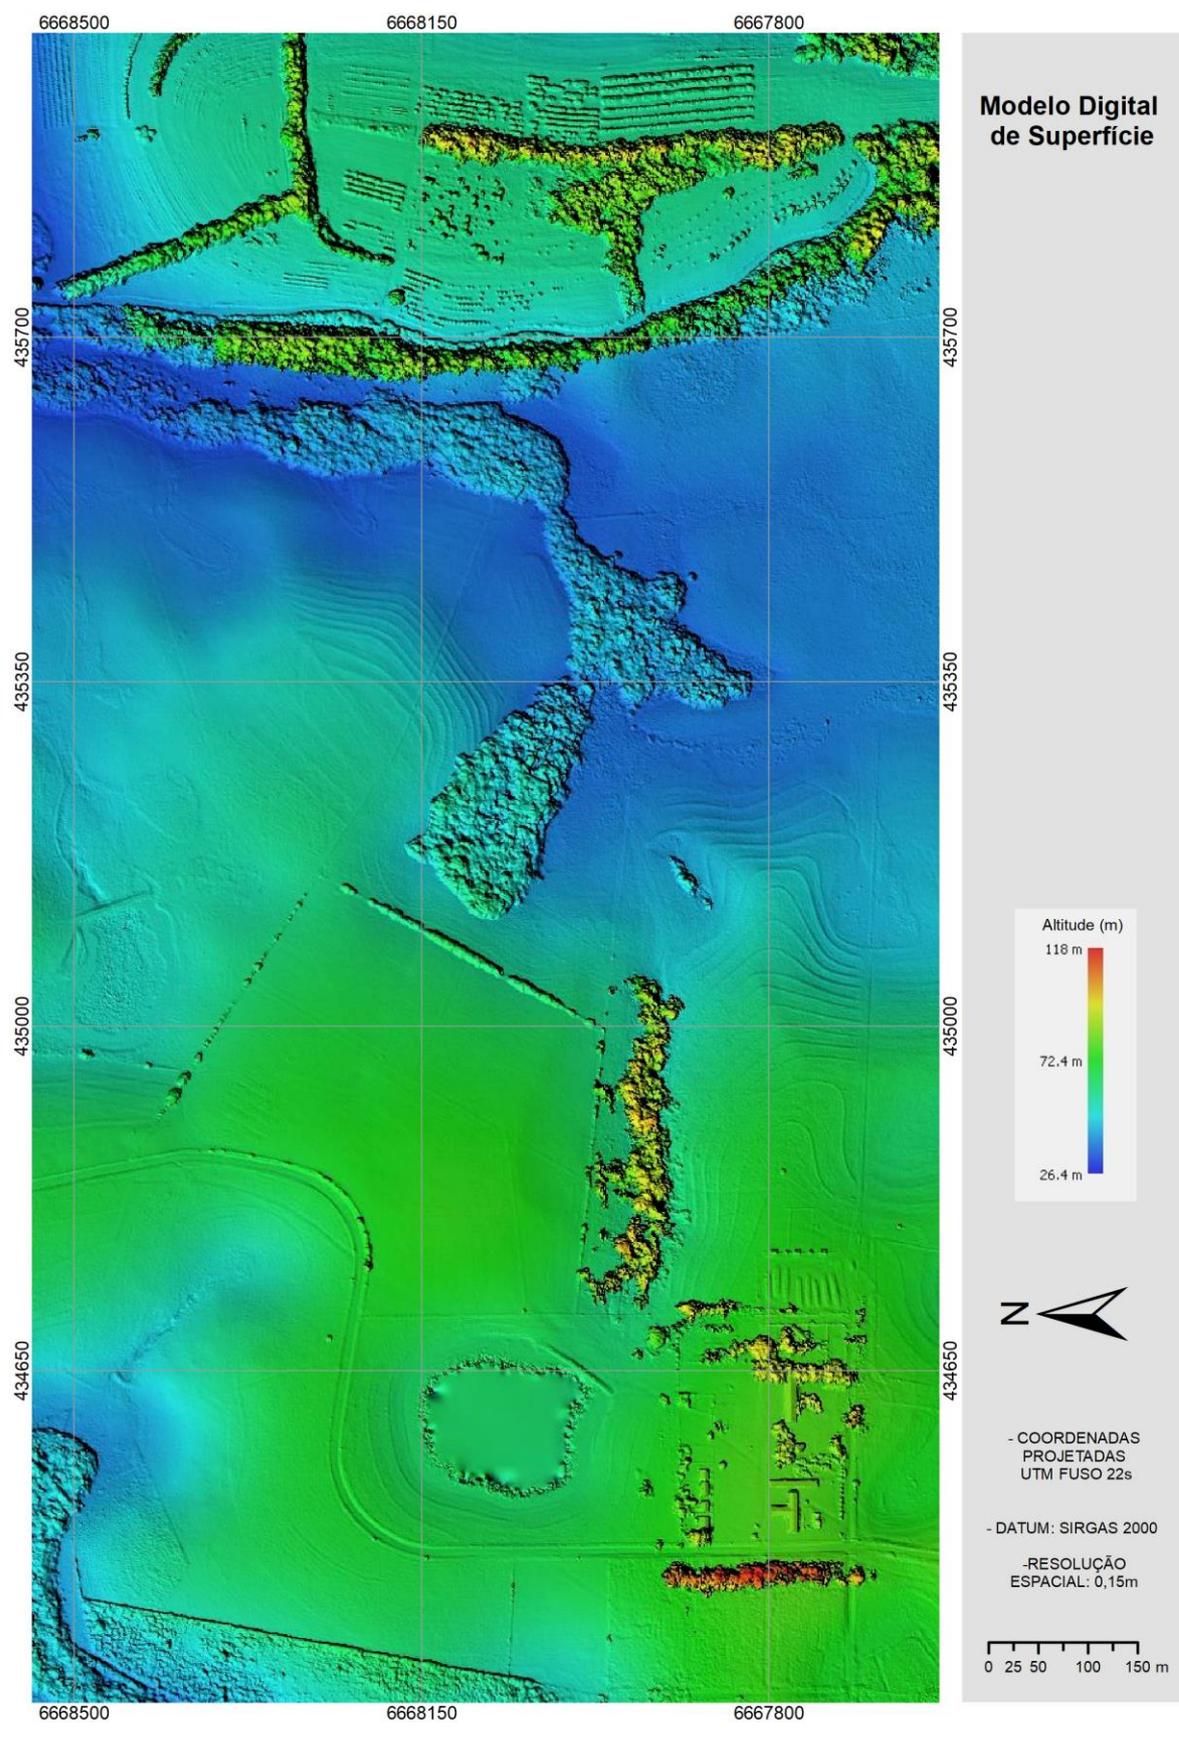


Figura 8 - Modelo Digital de Superfície.



Figura 9 - Mosaico de Ortofotos.

4.4 Aquisição e processamento dos dados orbitais do nanossatélite

As imagens dos nanossatélites foram adquiridas através da Interface gráfica do usuário da PlanetScope, utilizando uma licença que fornece imagens cobrindo áreas de até 10.000 km² por mês a projetos de pesquisa autorizados pela empresa. Utilizou-se uma imagem de 6 de junho de 2018, coincidindo com a data e horário das imagens do aerolevanteamento.

Neste estudo foram usados dois produtos *PlanetScope Ortho Scene* da banda 4 (NIR), que são corrigidos para reflectância de superfície. Estes foram disponibilizados no formato GeoTIFF, reamostrados para resolução espacial de 3 m, na projeção UTM e Datum WGS84, com resolução radiométrica de 16 bits (65.536 níveis de cinza) e com valores de reflectância escalonados para 10.000. Essas imagens foram agrupadas e estes mosaicos foram transformados pra a projeção UTM fuso 22 sul e Datum SIRGAS 2000, por fim os dados foram recordados considerando uma máscara vetorial da área de estudo.

4.5 Fusão das imagens fotogramétricas e orbitais

Para possibilitar a integração das imagens fotográficas de VANT com as imagens multiespectrais dos nanossatélites realizou-se o procedimento de fusão e reamostragem desses dados, objetivando a adequação dos tamanhos de pixel dos diferentes sensores.

Os processamentos foram realizados no software ERDAS IMAGINE 2015, onde inicialmente os dados do ortofotomosaico e do MDS, respectivamente com 8 e 15 centímetros de tamanho de pixel, tiveram seu pixel remostado para 30 centímetros, que é uma resolução espacial 10 vezes maior do que a das imagens PlanetScope. Proporções semelhantes foram utilizadas por Yilmaz e Gungor (2016) e Zhao *et al.* (2019), em estudos que aplicaram a fusão de imagens adquiridas com VANT e imagens de sensores orbitais. A seguir executou-se a produção da primeira componente principal derivada das cores primárias RGB do ortofotomosaico, para se obter uma imagem pancromática sintética. No processo de fusão por IHS essa imagem pancromática sintética foi utilizada para gerar uma imagem NIR fusionada

com resolução espacial de 30 cm. As imagens RGB e NIR com essa resolução espacial foram então utilizadas para a classificação do uso e cobertura da terra da área de estudo pela abordagem GEOBIA.

4.6 GEOBIA

Esta etapa abrangeu os processos necessários para a classificação dos dados. Para esse processamento foram utilizados os *softwares* eCognition developer 64 – 9.1, RStudio 1.1.1106 e ArcMap10.5. A Figura 10 apresenta os dados utilizados para a segmentação e classificação da imagem. A sequência executada cumpriu os estágios de definição das classes de cobertura e uso da terra, segmentação das imagens, classificação das imagens, e avaliação da exatidão da classificação e validação dos dados.

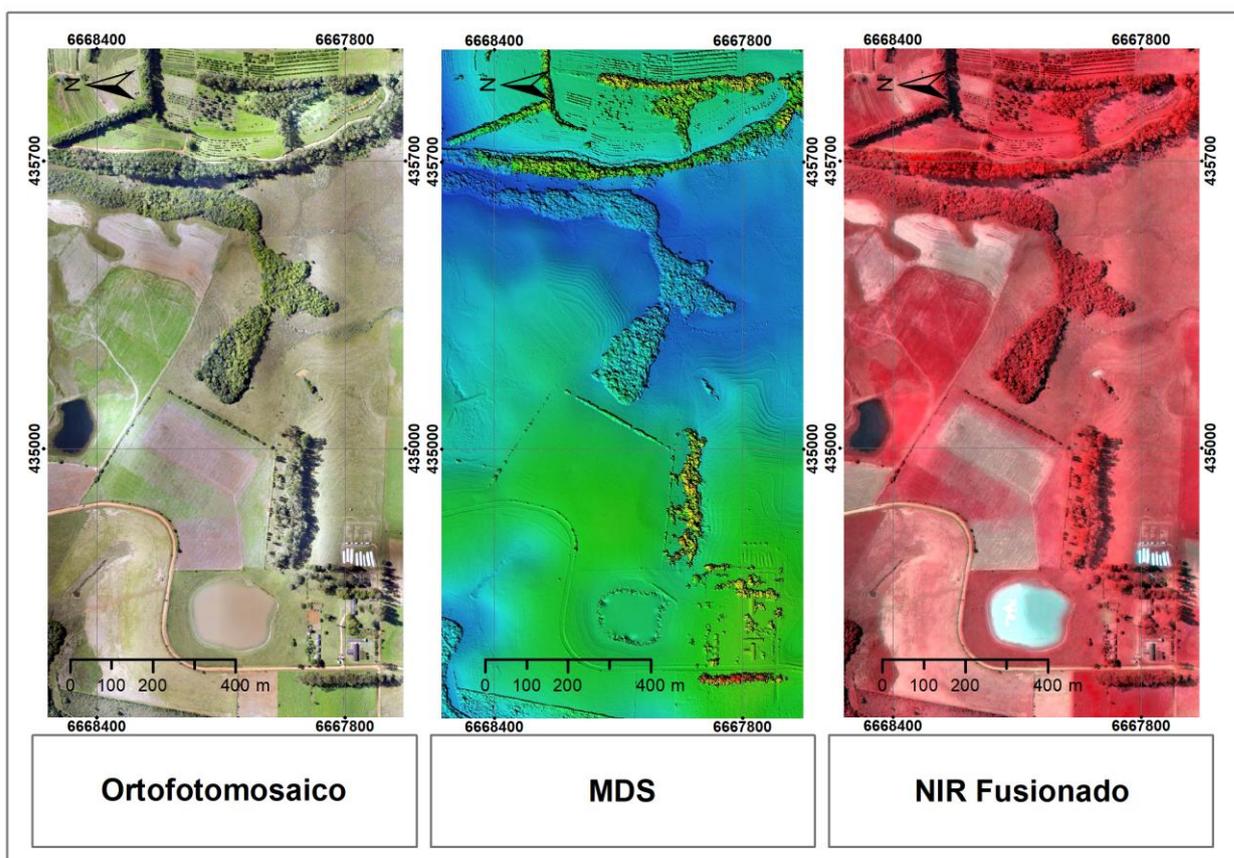


Figura 10 - Dados utilizados para a classificação.

A definição das classes foi feita com base em interpretação visual no ortofotomosaico e também por meio de relatórios fotográficos obtidos em trabalhos de campo realizados no local. Inicialmente foram definidas 42 subclasses, que foram agrupadas em 14 classes finais. As classes finais definidas foram as seguintes: mata nativa, campo sujo, campo limpo I, campo limpo II (campo nativo com maior biomassa e índice de massa foliar do que o campo nativo da classe campo limpo I), solo exposto, cultivo, pastagem, pomar, açude, açude eutrofizado, sombra, estrada, edificação e silo.

Após a definição das classes as imagens foram segmentadas no *software* eCognition para a extração dos objetos geográficos da imagem. Para a segmentação foram utilizadas as bandas do verde, vermelho, azul, infravermelho próximo (30 cm) e o MDS. Os parâmetros foram definidos pelo usuário de maneira empírica e foram adaptados às demandas da tarefa (BAATZ e SHAPE, 2000). Desta forma estabeleceram-se parâmetros de escala, forma e compacidade, com valores iguais a 50, 0,6 e 0,9, respectivamente. Optou-se por realizar uma supersegmentação, ou seja, o resultado da segmentação deu origem a objetos pequenos, aproveitando a alta resolução espacial dos dados oriundos do aerolevanteamento, totalizando 130.777 segmentos.

Com segmentação dos dados, foram definidos os atributos a serem extraídos para cada segmento (Tabela 4), os quais foram posteriormente exportados para o formato *shapefile*, e utilizados para o treinamento e classificação da imagem.

Tabela 4 - Atributos vinculados aos segmentos das imagens

| Categoria | Atributos |
|------------------|--|
| Espectral | Média (RGB), Desvio padrão (RGB), Brilho (RGB), Máxima diferença (RGB) |
| NIR | Média e Desvio Padrão |
| MDS | Mínimo, Máximo, Média, Amplitude, Desvio padrão, Soma (Declividade), Pixel máximo (Declividade), Pixel mínimo (Declividade), Desvio padrão (Declividade), Amplitude (Declividade), Média (Declividade) |
| Espaciais | Assimetria, Ajustes elíptico, Densidade, Raio maior, Raio menor, Direção principal, Índice de fronteira, Índice de forma, Compacidade |
| Textura | GLCM homogeneidade, GLCM correlação, GLCM Média, GLCM dissimilaridade |

Por meio do software ArcMap 10.5 foram coletadas manualmente um total de 2.139 amostras para treinamento do classificador, considerado um número mínimo de 30 amostras para cada subclasse. O treinamento e a classificação dos segmentos foram realizados no software Rstudio, utilizando os classificadores C5.0 (KUNH & QUINLAN, 2021) e o *Random Forest* (BREIMAN & CULTER, 2018).

Para cada um dos métodos utilizados foram realizadas seis classificações, com cinco conjuntos de atributos diferentes, variando os atributos utilizados, ou seja, ao todo foram realizados doze processamentos. Os conjuntos para cada classificação são apresentados na Tabela 5.

Tabela 5 - Atributos por conjunto de processamento

| Conjunto | Atributo |
|-----------------|--|
| 1 | Espectral |
| 2 | Espectral e NIR |
| 3 | Espectral, NIR e MDS |
| 4 | Espectral, NIR, MDS e Espaciais |
| 5 | Espectral, NIR, MDS e Textura |
| 6 | Espectral, NIR, MDS, Espaciais e Textura |

Após cada classificação as subclasses foram agrupadas nas 14 classes definidas inicialmente. Ao final passou-se à análise da exatidão dos dados obtidos em cada classificação. O objetivo desta etapa foi avaliar a influência dos atributos na obtenção dos resultados, além da eficácia de cada classificador. Para isso, a partir da interpretação visual do ortofotomosaico, foram selecionados segmentos que foram usados como checagem da exatidão da classificação, totalizando 1225 amostras de checagem, abrangendo as 14 classes de uso cobertura da terra. As amostras de treinamento e de validação podem ser visualizadas na Figura 11.



Figura 11 - Amostras de treinamento e de validação.

5 RESULTADOS E DISCUSSÕES

As matrizes de confusão dos processamentos do conjunto 1 de dados podem ser consultadas no Anexo III. Por meio destas, observamos que as classes mata nativa, campo limpo II e pomar apresentaram muitos casos de confusão entre si, assim como as classes de cultivo, campo limpo I e pastagem. A semelhança espectral dessas classes pode ser notada na Tabela 6, que apresenta os valores espectrais mínimo, máximo, média e de desvio-padrão para cada uma das classes, os quais foram extraídos por estatística zonal para as amostras de treinamento.

Observou-se que os melhores valores de Exatidão Global (EG) e Índice Kappa foram obtidos com o conjunto 6, utilizando o algoritmo *Random Forest* (Figura 12), com o uso de todas os atributos da Tabela 5. Os resultados foram valores de EG de 0,867 e de IK igual a 0,854, que caracterizam uma classificação de excelente qualidade. Para o algoritmo C5.0 a melhor solução (Figura 13) foi obtida com o conjunto 5, atingindo valores de EG de 0,839 e de IK de 0,823. Os valores de acurácia observados estão de acordo com outros estudos que utilizaram esses mesmos algoritmos, como no trabalho de Ruiz *et al.* (2017), em que esses autores avaliaram parâmetros do algoritmo C5.0 em área rural obtendo valores de 0,87 de EG e 0,83 para o IK.

Tabela 6 - Valores mínimo, máximo média e desvio-padrão por camada de informação das amostras de treinamento (os níveis digitais das imagens RGB e valores de reflectância estão escalonados para 10.000 nas imagens NIR)

| Classe | | Vermelho | Verde | Azul | IVP |
|------------------------|----------|----------|--------|--------|----------|
| 1 - Mata | MÍN | 6 | 7 | 0 | 5987 |
| | MÁX | 245 | 250 | 223 | 26032 |
| | M | 110,12 | 113,22 | 72,47 | 16324,50 |
| | σ | 42,53 | 41,82 | 27,06 | 4060,82 |
| 2 - Campo Sujo | MÍN | 40 | 32 | 6 | 6985 |
| | MÁX | 252 | 240 | 204 | 23398 |
| | M | 147,83 | 136,72 | 90,95 | 18309,15 |
| | σ | 37,96 | 32,08 | 33,11 | 3548,68 |
| 3- Campo Limpo I | MÍN | 46 | 43 | 9 | 7751 |
| | MÁX | 242 | 239 | 196 | 22769 |
| | M | 177,55 | 169,11 | 118,18 | 20705,23 |
| | σ | 30,08 | 29,17 | 28,94 | 2320,78 |
| 4 - Solo Exposto | MÍN | 62 | 57 | 28 | 10445 |
| | MÁX | 254 | 241 | 209 | 23507 |
| | M | 174,00 | 150,48 | 114,95 | 19938,97 |
| | σ | 26,83 | 27,10 | 26,29 | 3234,68 |
| 5 - Cultivo | MÍN | 49 | 58 | 0 | 9923 |
| | MÁX | 238 | 207 | 179 | 23709 |
| | M | 124,43 | 138,76 | 72,14 | 17633,79 |
| | σ | 18,41 | 15,54 | 18,02 | 1822,62 |
| 6 - Campo Limpo II | MÍN | 56 | 74 | 10 | 11550 |
| | MÁX | 254 | 252 | 251 | 24584 |
| | M | 156,47 | 165,74 | 88,06 | 20473,25 |
| | σ | 20,10 | 18,49 | 20,59 | 1868,98 |
| 7 - Pastagem | MÍN | 41 | 52 | 6 | 8619 |
| | MÁX | 217 | 207 | 149 | 23759 |
| | M | 130,12 | 144,94 | 73,01 | 18261,38 |
| | σ | 17,87 | 14,21 | 14,23 | 1724,03 |
| 8 - Pomar | MÍN | 11 | 26 | 0 | 6246 |
| | MÁX | 255 | 242 | 211 | 23470 |
| | M | 110,05 | 116,47 | 66,93 | 15801,79 |
| | σ | 54,47 | 46,73 | 34,52 | 4598,63 |
| 9 - Açude | MÍN | 23 | 32 | 33 | 6522 |
| | MÁX | 184 | 162 | 123 | 22970 |
| | M | 96,94 | 91,25 | 73,24 | 12002,57 |
| | σ | 66,10 | 47,97 | 27,22 | 4380,25 |
| 10 - Açude Eutrofizado | MÍN | 37 | 41 | 15 | 7324 |
| | MÁX | 181 | 177 | 127 | 23458 |
| | M | 122,80 | 117,69 | 80,84 | 15404,72 |
| | σ | 31,52 | 28,39 | 20,76 | 2069,25 |
| 11 - Sombra | MÍN | 0 | 9 | 7 | 5426 |
| | MÁX | 254 | 254 | 254 | 25055 |
| | M | 32,67 | 41,74 | 44,05 | 8283,46 |
| | σ | 13,90 | 13,57 | 12,77 | 1855,86 |
| 12- Estrada | MÍN | 132 | 113 | 65 | 17319 |
| | MÁX | 255 | 246 | 204 | 23164 |
| | M | 213,90 | 172,27 | 123,28 | 22243,82 |
| | σ | 17,19 | 20,21 | 21,74 | 370,05 |
| 13 - Edificação | MÍN | 52 | 57 | 19 | 10145 |
| | MÁX | 254 | 255 | 248 | 23582 |
| | M | 137,68 | 127,69 | 112,99 | 17912,25 |
| | σ | 35,27 | 34,26 | 33,64 | 3373,11 |
| 14 - Silo | MÍN | 117 | 116 | 122 | 13853 |
| | MÁX | 255 | 255 | 255 | 28119 |
| | M | 235,45 | 236,29 | 235,99 | 25639,22 |
| | σ | 22,73 | 22,47 | 21,89 | 2150,18 |

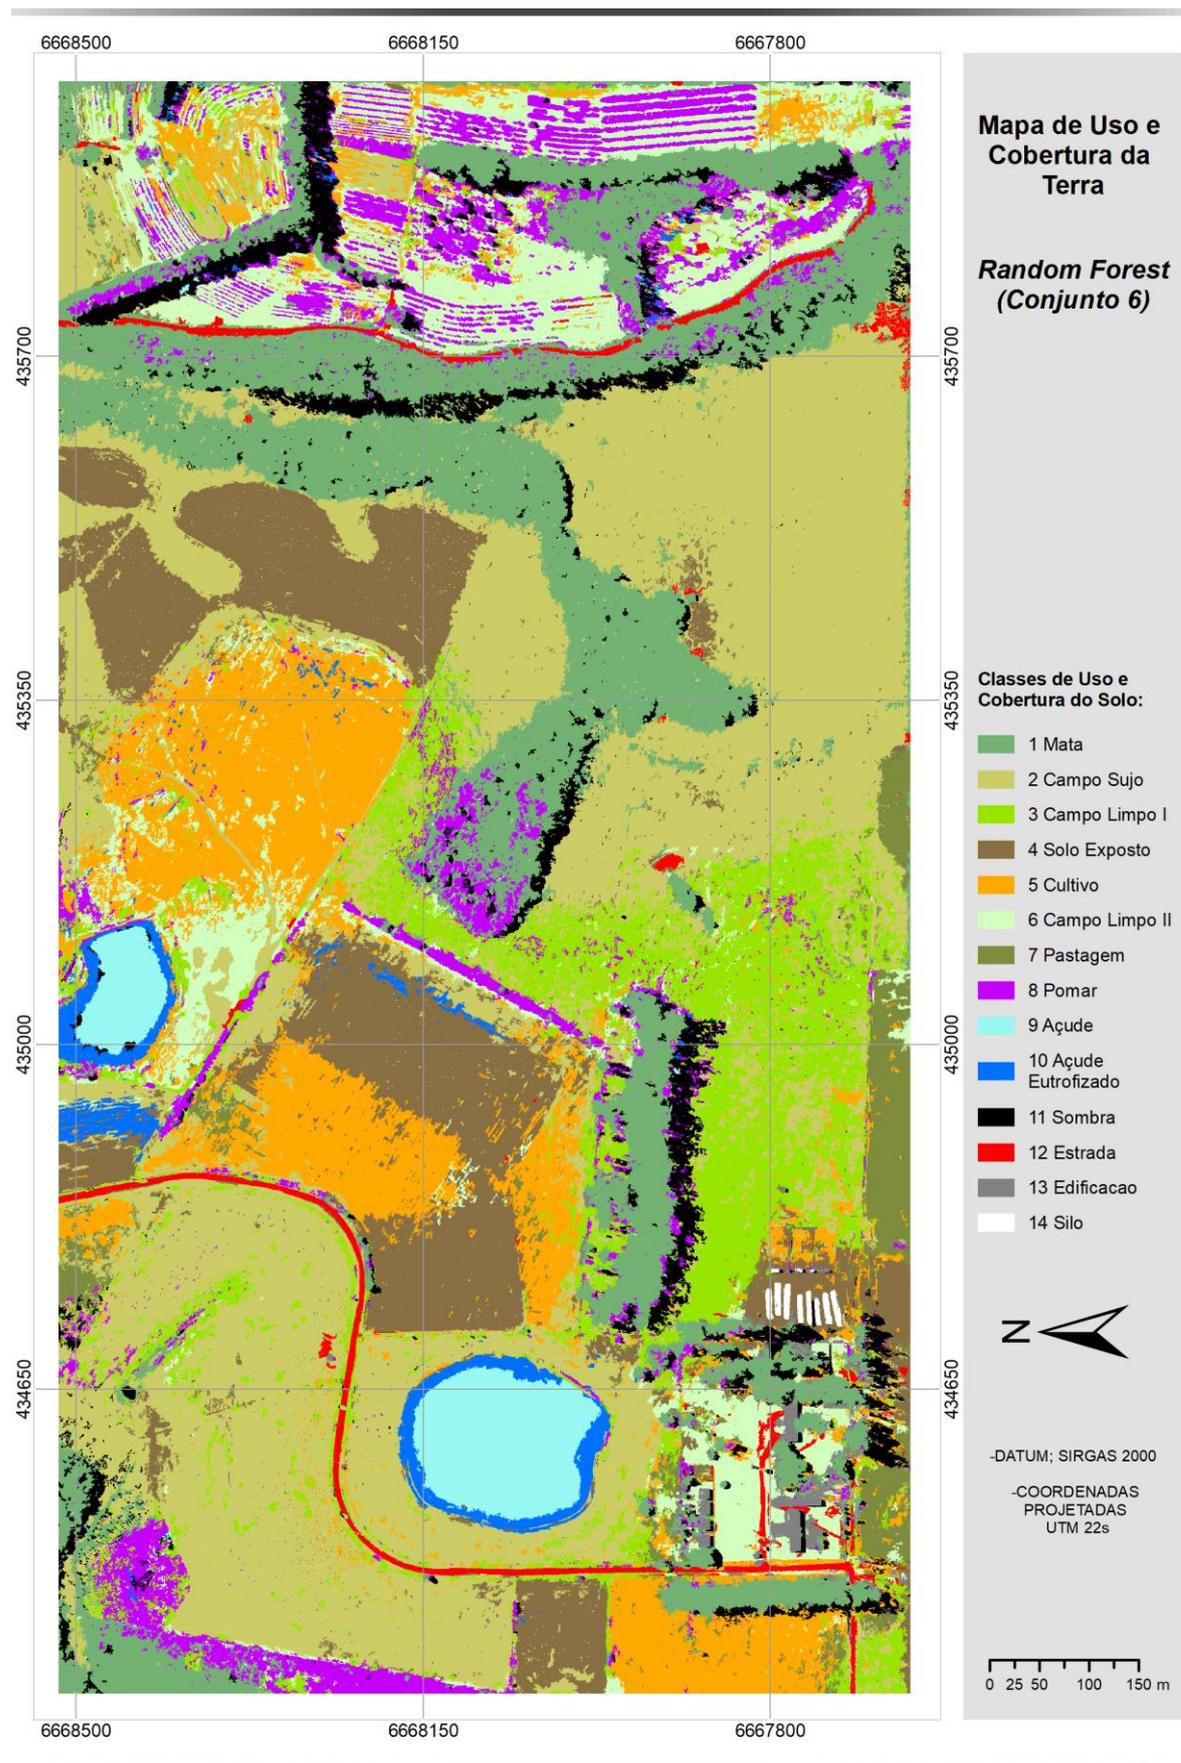


Figura 12 - Classificação por *Random Forest* (processamento do conjunto 6).

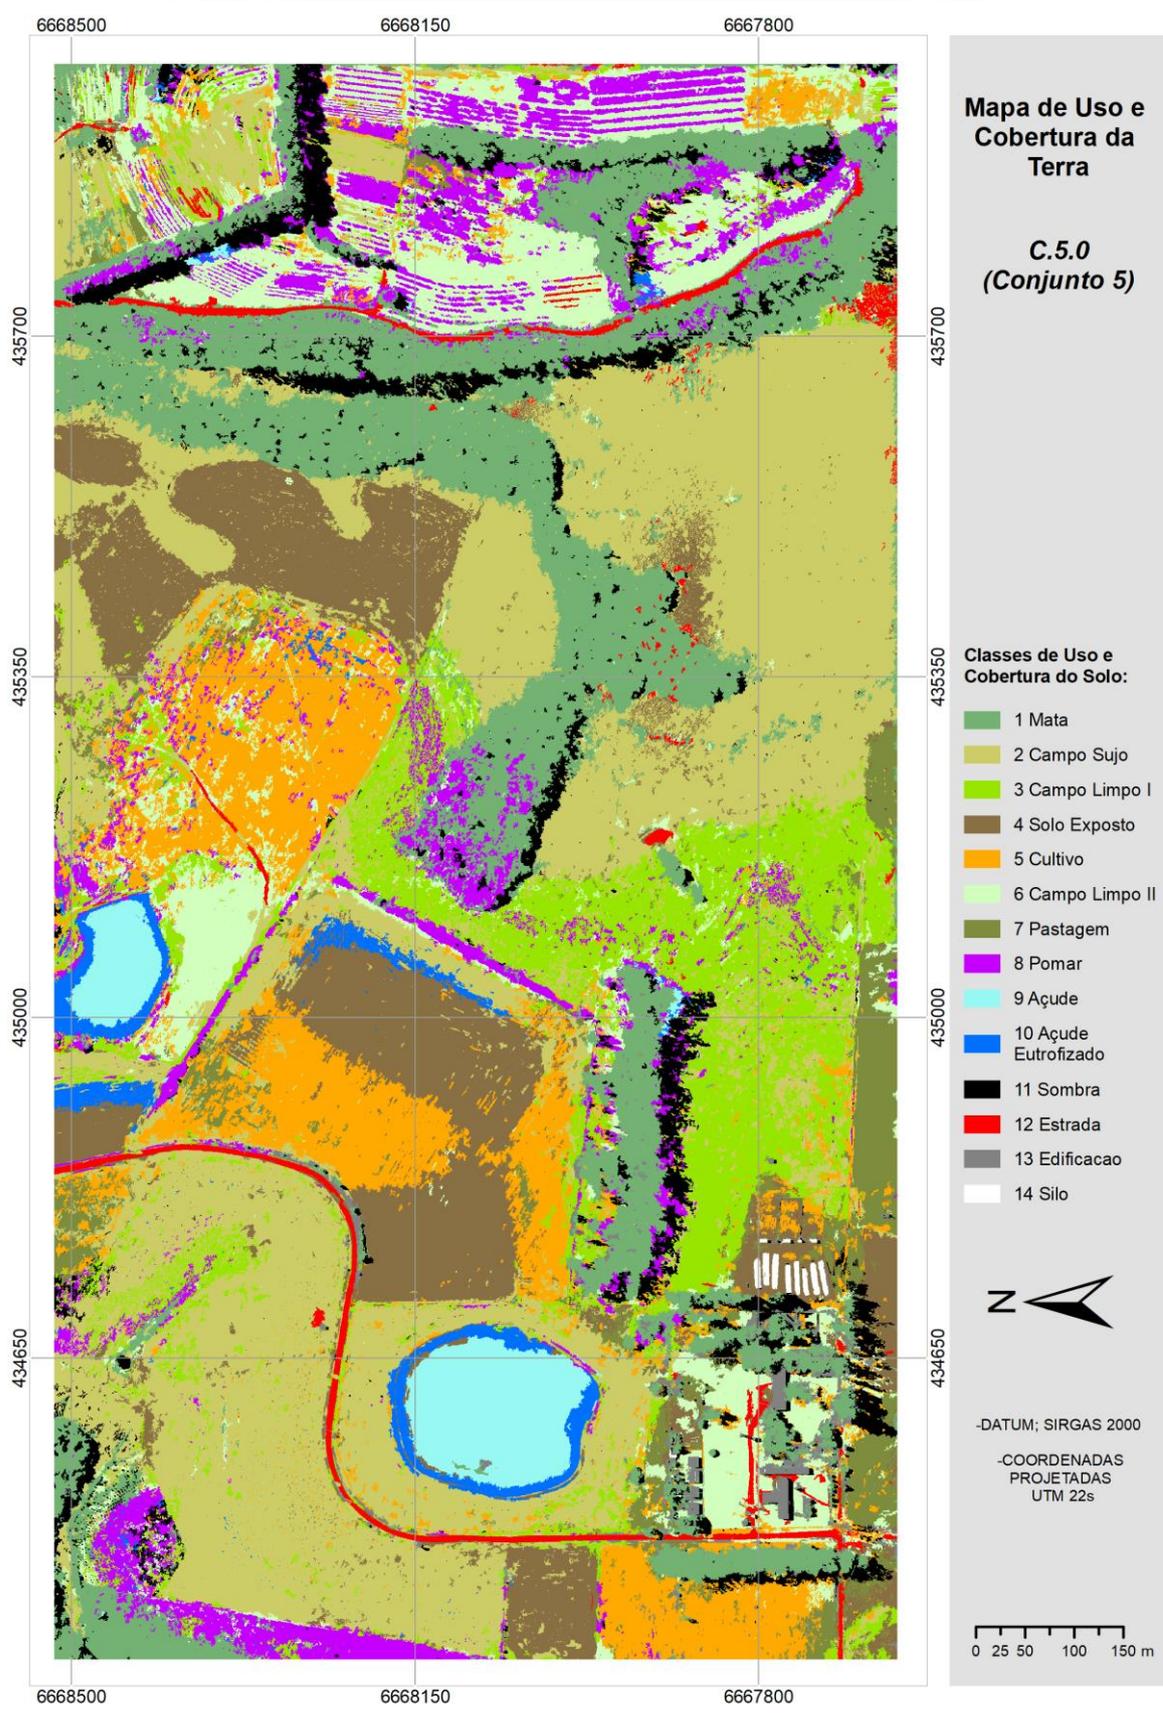


Figura 13 - Classificação pelo algoritmo C5.0 (processamento do conjunto 5).

Assim como observado por Moraes (2018) que realizou um trabalho semelhante utilizando os mesmos algoritmos em um contexto urbano, os valores de EG e IK do *Random Forest* apresentaram melhores resultados quando comparados com os obtidos pelo C5.0. Os dados deste estudo mostraram que todas as classificações que incluíram os atributos do MDS (conjuntos de 3 a 6), apresentaram resultados excelentes. Os processamentos dos conjuntos 1 e 2, com valores de IK inferiores a 0,8, foram consideradas muito bons. As Figuras 14 e 15 mostram os valores de EG e o IK para os seis processamentos realizados para cada um dos dois algoritmos. Estes valores foram obtidos pelas matrizes de confusão geradas para a análise de acurácia de cada processamento e que podem ser consultadas no ANEXO III.

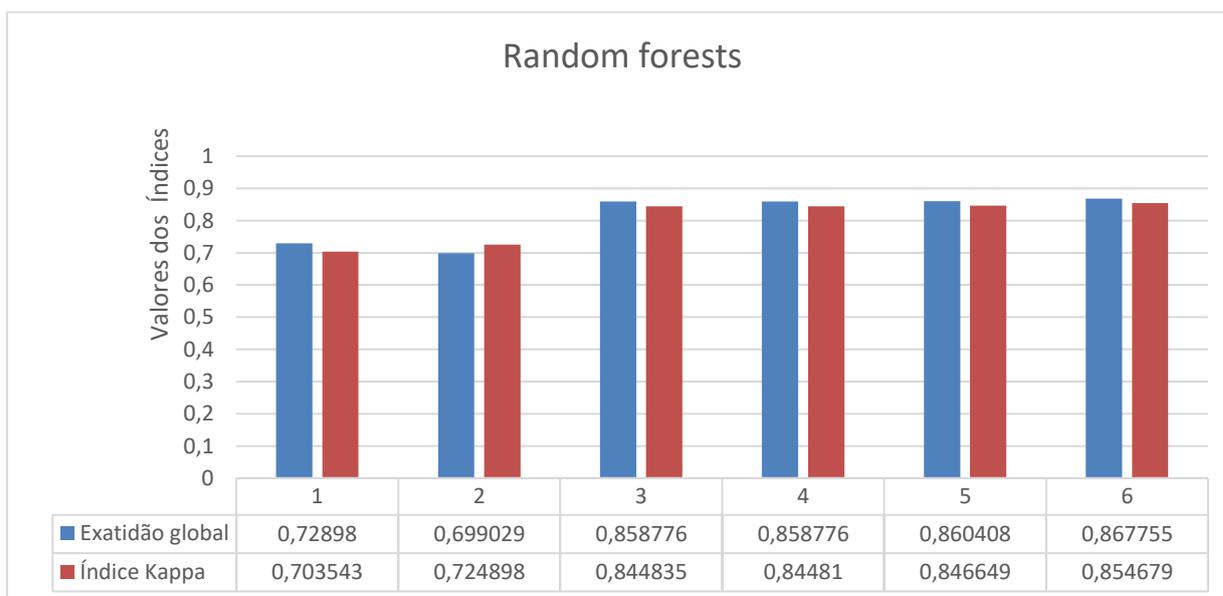


Figura 14 - Valores de Exatidão Global e Índice Kappa para as classificações com o algoritmo *Random Forest*.

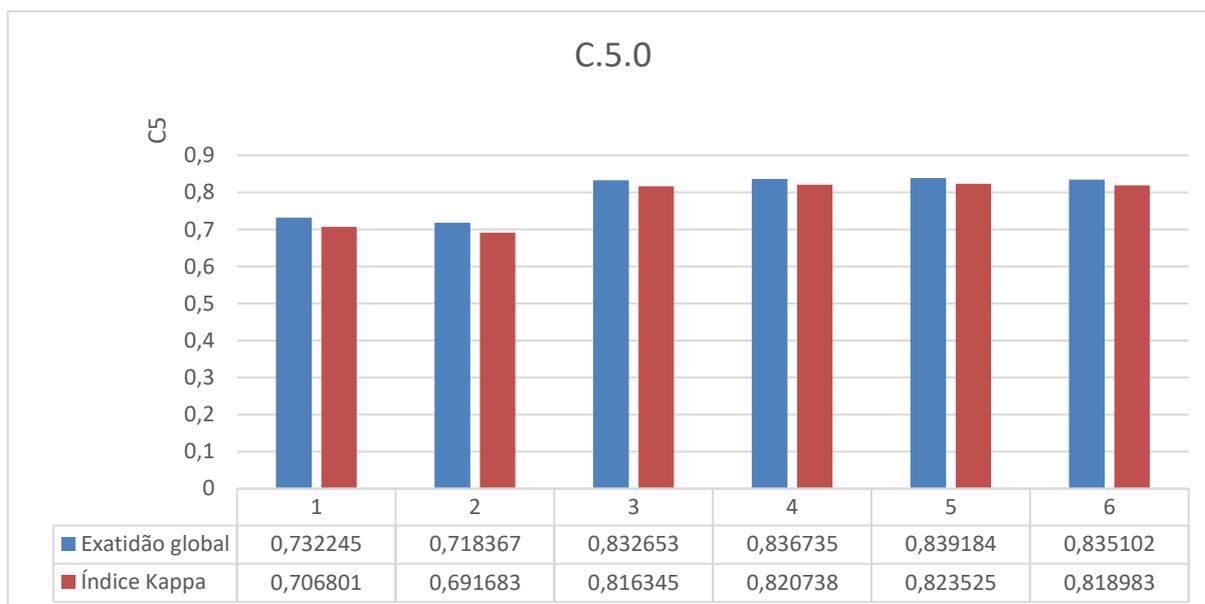


Figura 15 - Valores de Exatidão Global e Índice Kappa para as classificações com o algoritmo C5.0

Zhao *et al.* (2019), em um estudo com imagens de VANT fusionadas com dados do Sentinel-2A, concluíram que em geral as imagens fusionadas atingem maiores precisões do que na classificação dos dados separadamente. Nesta pesquisa a análise das exatidões alcançadas nos processamentos que incluíram os atributos relacionados ao NIR não indicou ganho de qualidade nas classificações. Isso ocorreu tanto na classificação pelo algoritmo *Random Forest* quanto pelo C5.0, observado nas Figuras 14 e 15. O acréscimo dos dados do NIR (Conjunto 2) ocasionaram uma diminuição nos valores de EG e de IK. Esse resultado pode ser explicado pela elevada diferença das resoluções espacial e radiométrica entre os dados da imagem do NIR e das fotografias do aerolevante, além das condições de iluminação das imagens do VANT sofrerem maior influência da variação da iluminação solar ao longo do dia e também pela cobertura de nuvens, em decorrência do intervalo de tempo necessário para realizar a aquisição das imagens.

Al-Najjar *et al.* (2019) relataram um aumento de 1,2% na EG da classificação ao utilizar um MDS obtido por meio de VANT, quando comparado à classificação gerada apenas com um ortofotomosaico. Neste estudo os atributos relacionados ao MDS foram os que mais contribuíram para o aumento da exatidão das classificações. No processamento com os dois algoritmos houve significativo incremento nos valores de EG e IK nos processamentos que foram realizadas com conjunto de 3 de atributos

(Figuras 14 e 15). Além disso, na execução do treinamento das amostras, apresentado tanto pelo RF quanto pelo C5.0, os atributos relacionados ao MDS tiveram destaque na importância estimada pelo classificador. No gráfico de *Mean Decrease Accuracy*, métrica que expressa o quanto se perde em acurácia do modelo ao excluir um determinado atributo, os atributos valor máximo de pixel do MDS e a média do MDS foram os que tiveram maior importância, corroborando com as observações de crescimento nos valores de EG e IK nos processamentos realizados com os atributos do conjunto 3 (Figuras 14 e 15)

A Figura 16 mostra o resultado das classificações geradas a partir dos processamentos do algoritmo *Random Forest*. O resultado obtido com o conjunto 3 mostra uma maior definição tanto no interior quanto nas fronteiras dos limites das classes, quando comparado com os resultados obtidos com os conjuntos 1 e 2.

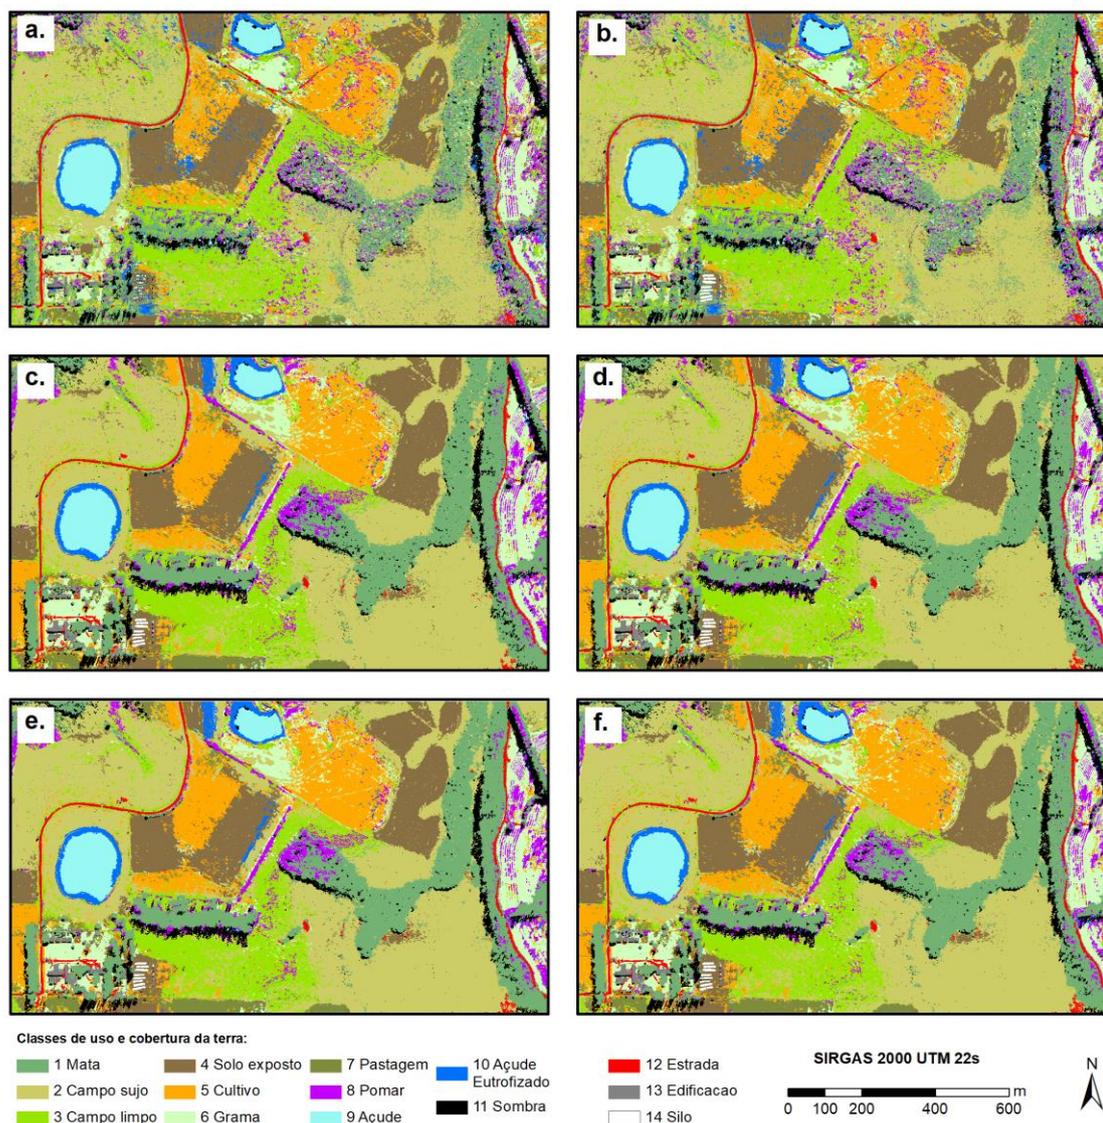


Figura 16 - Uso e cobertura da terra pelo algoritmo *Random Forest* para o conjunto 1 (a); conjunto 2 (b); conjunto 3 (c); conjunto 4 (d); conjunto 5 (e); e conjunto 6 (f)

Na figura 17 são apresentados os resultados obtidos com o algoritmo C.5.0. A análise dos mapas gerados a partir dos conjuntos 1 (Figura 17 a.) e 3 (Figura 17 c.) reforça a importância do uso dos atributos do MDS para o aumento da exatidão da classificação.

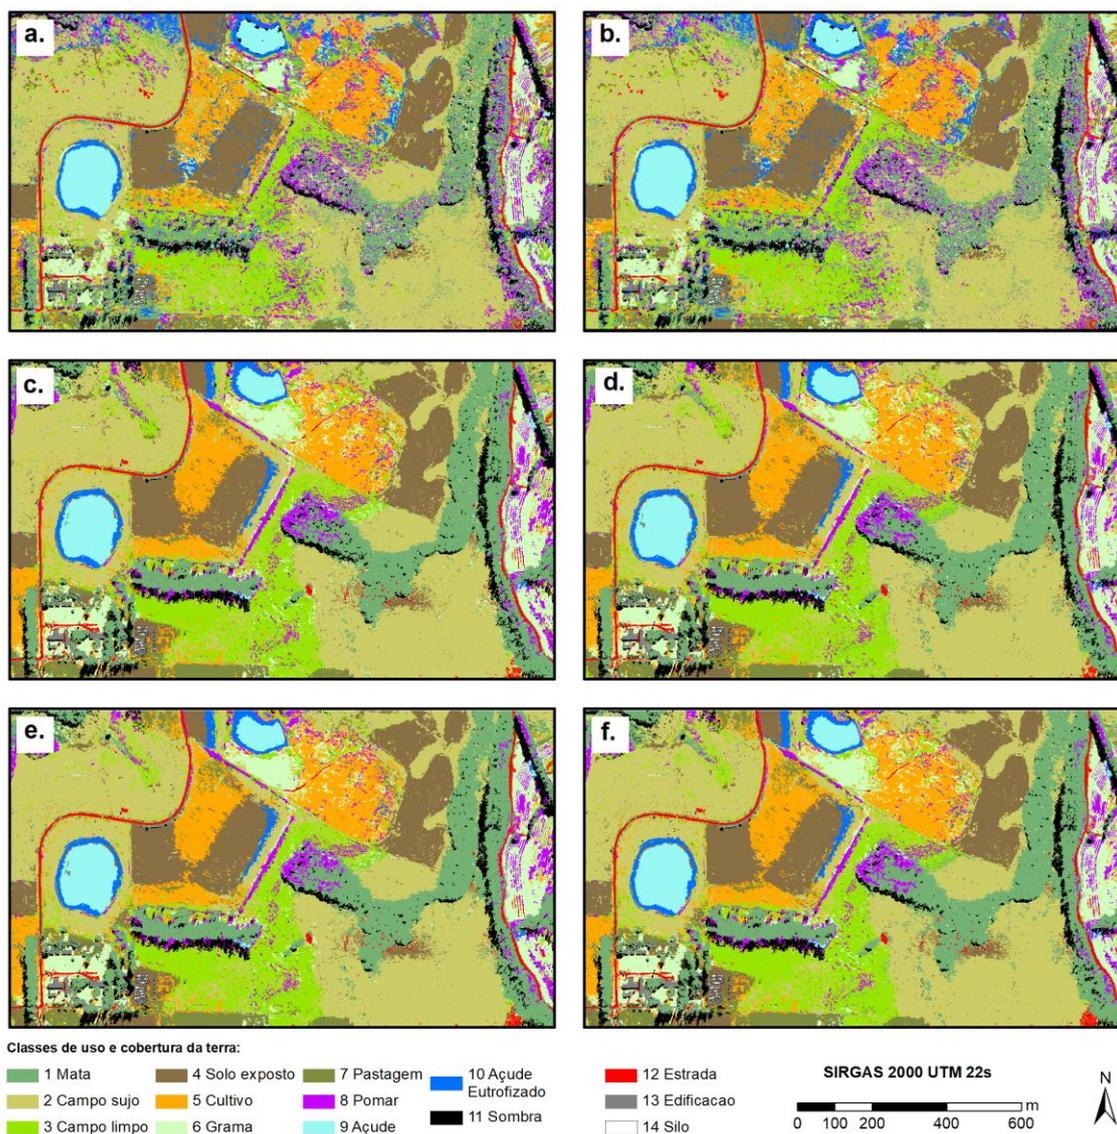


Figura 17 - Uso e cobertura da terra pelo algoritmo C.5.0 para o conjunto 1 (a); conjunto 2 (b); conjunto 3 (c); conjunto 4 (d); conjunto 5 (e); e conjunto 6 (f)

A estimativa dos atributos mais importantes para a acurácia na classificação para os algoritmos *Random Forest* e C5.0 é apresentada na Figura 18 (*Mean Decrease Accuracy*), nos processamentos que englobaram todas as variáveis (conjunto 6). Destaca-se que as variáveis espaciais, agregadas aos processamentos a partir do conjunto 4, relacionadas à geometria dos segmentos, foram as que tiveram menor peso nas estimativas do classificador. Isso pode ser explicado pela opção de se realizar uma supersegmentação da imagem, a qual gerou segmentos de tamanho reduzido e com geometria homogênea, favorecendo as variáveis relacionadas aos

dados com maior resolução espacial, que são os atributos espectrais, oriundos do ortofotomosaico, além dos relacionados ao MDS.

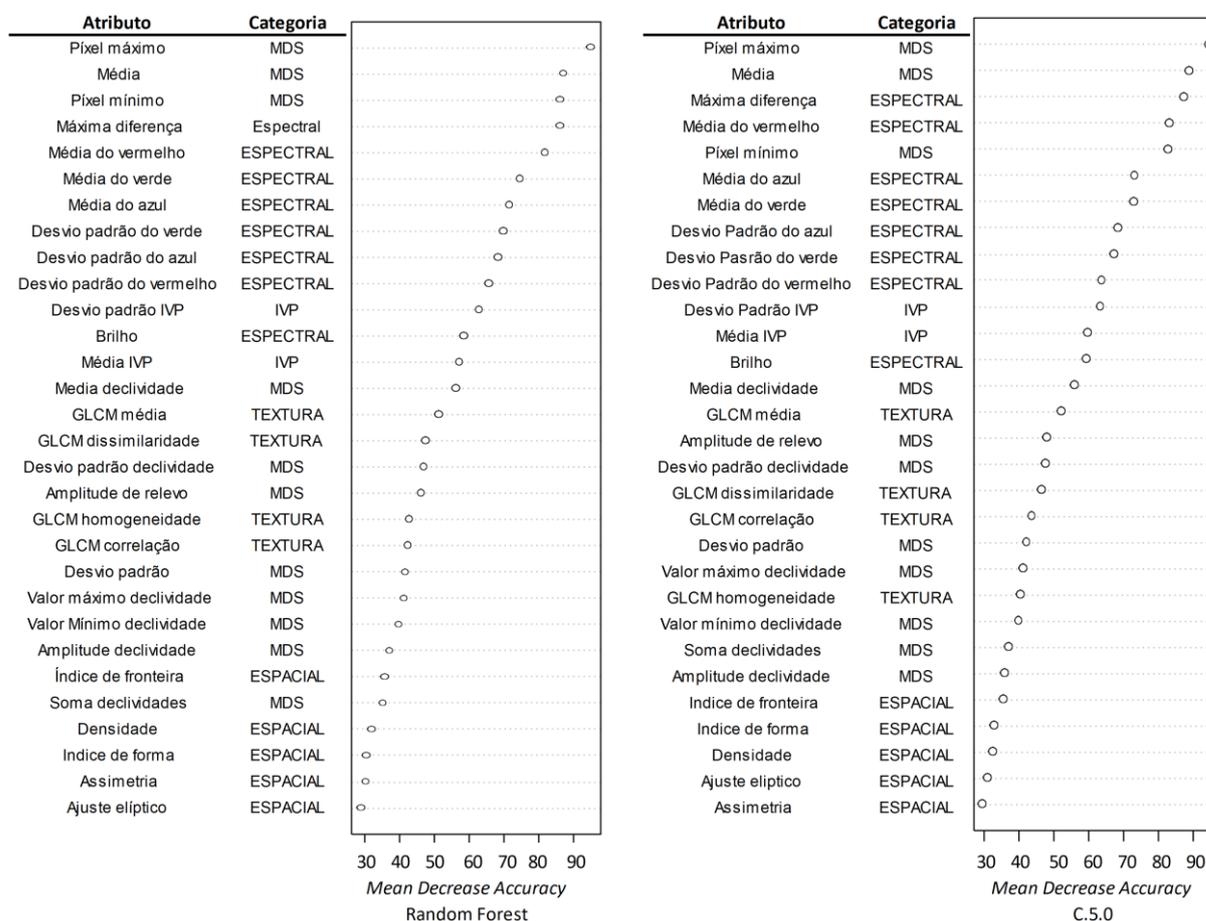


Figura 18 - Mean Decrease Accuracy para os algoritmos *Random Forest* e *C5.0* (conjunto 6)

Os parâmetros de textura utilizados nesse estudo foram os de Haralick *et al.* (1973), calculados com base na matriz de co-ocorrência de níveis de cinza (*Gray-Level Co-Occurrence Matrix* - GLCM). Os processamentos do conjunto 5 foram realizados com o intuito de avaliar a influência desses atributos de textura. Ao contrário do que apontaram Kwak e Park (2019), que consideraram importantes os atributos de textura como influentes na classificação de dados VANT com pixel de 25 cm, os indicadores de IK e EG (Figuras 14 e 15) dos conjuntos 4 e 5 deste estudo não apontaram incremento nos resultados das classificações, tanto para o processamento com o RF quanto para com o algoritmo C5.0.

Os gráficos apresentados das Figuras 19 e 20 mostram as variações de acurácia obtidas em cada classe e a relação com os conjuntos de dados utilizados nas classificações. Observou-se uma tendência geral de aumento nos valores de acurácia em todas as classes nos resultados das classificações que utilizaram os atributos oriundos do MDS (Conjuntos 3, 4, 5 e 6) na comparação com os valores de acurácia dos resultados das duas primeiras classificações (Conjuntos 1 e 2). Além destes gráficos pode-se notar pelas Tabelas 7 e 13 (Anexo III) que os alvos com maior homogeneidade espectral foram os que tiveram maiores erros nas classificações do conjunto 1 de dados.

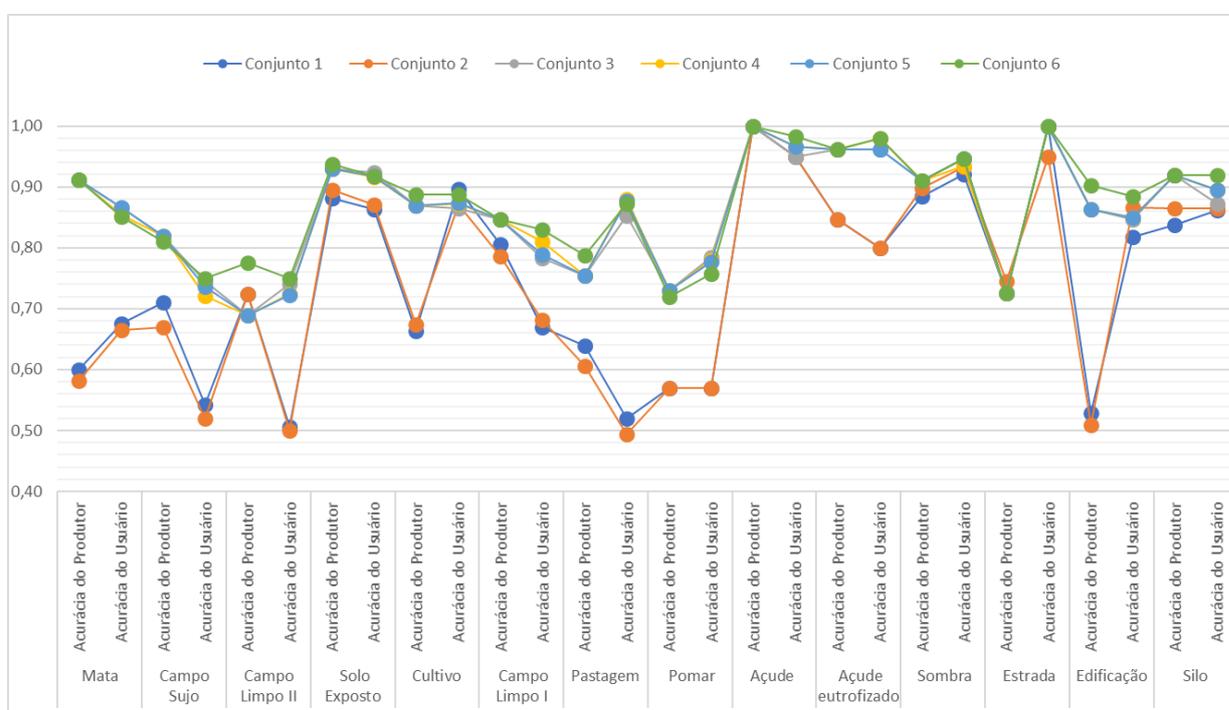


Figura 19 - Acurácia do produtor e do usuário por classe para as classificações realizadas com *Random Forest*.

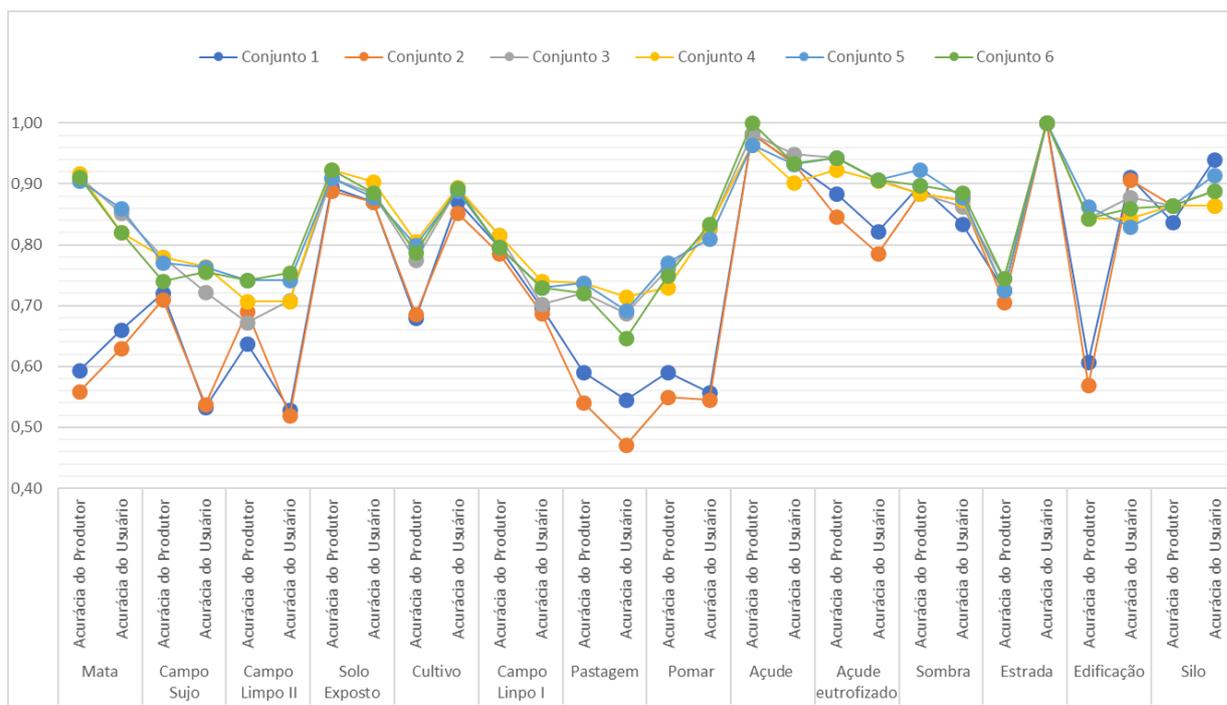


Figura 20 - Acurácia do produtor e do usuário por classe para as classificações realizadas com C5.0.

Para a classificação pelo *Random Forest*, as classes que mais tiveram ganho na acurácia de produtor entre os conjuntos 1 e 3 foram as de mata, edificação, pomar e açude eutrofizado como pode ser observado nas tabelas 7 e 9 do anexo III. Nas classificações pelo C5.0, em uma comparação entre os mesmos conjuntos, as classes que mais contribuíram para o aumento dos valores de acurácia do produtor foram as de mata, edificação, pomar e pastagem (Tabelas 13 e 15 - Anexo III).

Em uma análise qualitativa, a partir da observação dos resultados das melhores classificações com os dois algoritmos utilizados nesta pesquisa (Figuras 12 e 13), constatou-se que a abordagem GEOBIA foi satisfatória para a discriminação dos diferentes alvos presentes na área de estudo. Na classificação pelo *Random Forest* as classes apresentaram maior contiguidade, no entanto pelo C5.0 estas ficaram mais fragmentadas. Esse resultado reforça que o RF tem acidade para classificar conjuntos de dados com elevada variância, conforme relatado por Mota, 2019.

O aerolevantamento foi realizado no inverno, quando os ângulos de iluminação solar são menores do que nas outras estações, mesmo com a realização dos voos em horários próximos ao meio dia. Isso provoca a geração de sombras nas imagens

e, portanto, acarreta no aumento da confusão na execução das classificações. Além disso as imagens coletadas por VANT neste estudo possuem altíssima resolução espacial e alta variação espacial de brilho. Isso gerou maior dificuldade na separação de algumas classes como por exemplo, de mata, campo e pomar. Outras classes que apresentaram similaridade espectral entre si foram solo exposto e açude eutrofizado, e a classe estrada e alguns pequenos reservatórios de água com partículas em suspensão, utilizados para dessedentação de animais.

6 CONCLUSÕES

O objetivo deste trabalho consistiu no uso combinado de fotografias obtidas por uma câmera de altíssima resolução espacial e baixo custo de aquisição, acoplada a um VANT, com uma imagem sintética da banda NIR de nanossatélite, e na avaliação da acurácia de classificação do uso e cobertura da terra gerada por meio da segmentação dessas imagens e da aplicação de algoritmos de aprendizado de máquina. Apesar dos resultados não apontarem ganho de qualidade ao combinar os dados orbitais de maior resolução espectral com os dados de aerolevanteamento utilizados neste trabalho, a câmera de altíssima resolução espacial mostrou aplicabilidade para fornecer uma gama de informações necessárias para o mapeamento da cobertura e uso da terra de áreas rurais.

Observou-se um incremento na separabilidade das classes e na qualidade das classificações como função dos conjuntos de atributos calculados a partir do mosaico RGB de ortofotos (máxima diferença e média da banda do vermelho) e do MDS (valores mínimo, máximo e médio), gerado a partir dos dados adquiridos por VANT. A partir da análise dos resultados de exatidão das classificações, pode-se concluir que os classificadores por árvores de decisão Boosted C5.0 e *Random Forest* possibilitaram a obtenção de resultados satisfatórios na classificação do uso e cobertura da terra, com Índice Kappa igual a 0,82 e 0,85, respectivamente.

Os atributos de textura não contribuíram para o aumento nos indicadores de acurácia das classificações. Isso ocorreu provavelmente devido à reamostragem do ortofotomosaico. Tais atributos podem variar de acordo com o tamanho dos pixels da imagem e com a qualidade da câmera e do aerolevanteamento realizado. Assim, mais experimentos em outras áreas e com diferentes configurações de voo e processamento poderiam ser realizados para avaliar a influência das informações de textura no contexto da classificação por GEOBIA.

A principal limitação deste estudo se deu no uso dos dados NIR dos nanossatélites PlanetScope, justamente a hipótese principal deste trabalho. Os processos necessários para a adequação da resolução espacial e a grande diferença entre as dimensões de pixel do sensor orbital e da câmera embarcada no VANT fizeram com que o conjunto de atributos oriundos do NIR não contribuíssem no incremento da acurácia das classificações. Como recomendação para futuros

trabalhos, deve ser investigada a influência das outras bandas do PlanetScope, assim como a derivação de índices de vegetação desses dados além de testes de fusão considerando diferentes escalas para os dados oriundos de aerolevanteamento.

Por outro lado, os processamentos nos quais foram utilizados os dados oriundos da câmera fotográfica do VANT com os atributos derivados do MDS mostraram grande potencial na classificação da cobertura e uso da terra da área rural estudada. Os resultados mostraram que a aplicação de produtos e subprodutos gerados a partir de dados obtidos com sensores de baixo custo, bastante difundidos no mercado de mapeamento, com altíssima resolução espacial e baixa resolução espectral, podem gerar uma classificação de boa qualidade para áreas rurais aplicando técnicas de GEOBIA. Estes mapeamentos automáticos podem ser aplicados de diferentes formas para o mapeamento e a gestão dessas regiões.

7 REFERÊNCIAS

AASEN, H., HONKAVAARA, E., LUCIEER, A., & ZARCO-TEJADA, P. J. 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.

AL-NAJJAR, H.A.H.; KALANTAR, B.; PRADHAN, B.; SAEIDI, V.; HALIN, A. A.; Ueda, N.; Mansor, S. 2019. Land Cover Classification from fused DSM and UAV Images Using Convolutional Neural Networks. **Remote Sensing**, 11, 1461. <https://doi.org/10.3390/rs11121461>

ANAC (Agência Nacional de Aviação Civil). Quantidade de Cadastros – Drones. Disponível em: < <https://www.gov.br/anac/pt-br/assuntos/drones/quantidade-de-cadastros>> Acesso em: 02/09/2021

ANTUNES, D. CONTI, G, WIGGERS K. L. RIBEIRO S. R. A.. Abordagens em GEOBIA e aplicação da técnica em imagem Rapideye de uma área da bacia do rio Pitangui - PR. In: **5º Simpósio de Geotecnologias no Pantanal**, Campo Grande - MS, v. 5, n. 1. Anais, p.631-640, nov. 2014.

BAATZ, M., SCHAPE, A. Multiresolution segmentation: an optimum approach for high quality multi scale image segmentation. 2000

BAYLOR, M. Planet Labs Targets a Search Engine of the World. 2018. Disponível em: <<https://www.nasaspaceflight.com/2018/01/planet-labs-targets-search-engine-world/>>. Acesso em: 25 jan. 2021.

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

BERNI, J.; ZARCO-TEJADA, P.J.; SUAREZ, L.; FERERES, E. Thermal and Narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. **IEEE Transactions On Geoscience And Remote Sensing**, [S.L.], v. 47, n. 3, p. 722-738, mar. 2009. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tgrs.2008.2010457>.

BLACKWELL, W; CAHOY, K; ERICKSON, NI. MicroMAS: A First Step Towards a Nanosatellite Constellation for Global Storm Observation. In: **Small Satellite Conference, 2013**, Logan, Utah. Proceedings. Logan: Anais, 2013. p. 1 - 10. Disponível em: <<https://digitalcommons.usu.edu/cgi/viewcontent.cgi?article=2985&context=smallsat>>. Acesso em: 20 jan 2021

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS journal of photogrammetry and remote sensing**, v. 65, n. 1, p. 2-16, 2010.

BLASCHKE, T.; HAY, G. J.; KELLY, M.; LANG, S.; HOFMANN, P.; ADDINK, E.; FEITOSA, R. Q.; MEER, F; WERFF, H.; VAN COILLIE, F. Geographic Object-Based Image Analysis – Towards a new paradigm. **Isprs Journal Of Photogrammetry And Remote Sensing**, [S.L.], v. 87, p. 180-191, jan. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.isprsjprs.2013.09.014>.

BLASCHKE, T.; KUX, H. Sensoriamento Remoto e SIG Avançados: Novos Sistemas Sensores, Métodos Inovadores. 2. Ed. São Paulo: Oficina de Textos, 2007.

BÖHLER, J.; SCHAEPMAN, M.; KNEUBÜHLER, M. Crop Classification in a Heterogeneous Arable Landscape Using Uncalibrated UAV Data. **Remote Sensing**, [S.L.], v. 10, n. 8, p. 1282, 14 ago. 2018. MDPI AG. <http://dx.doi.org/10.3390/rs10081282>.

BREIMAN, L. Random Forests. **Machine Learning**, [S.L.], v. 45, n. 1, p. 5-32, 2001. Springer Science and Business Media LLC. <http://dx.doi.org/10.1023/a:1010933404324>.

BREIMAN, L., CULTER, A. Breiman and Cutler's Random Forest for Classification and Regression, 2018. disponível em: <<https://cran.rstudio.com/web/packages/randomForest/randomForest.pdf>>. Acesso em 10 de agosto de 2021.

BRITO, J. N.; COELHO, L. Fotogrametria Digital. Rio de Janeiro: **Eduerj**, 2007.

CAO, W.; LI, B.; ZHANG, Y. A remote sensing image fusion method based on PCA transform and wavelet packet transform. **IEEE International Conference on Neural Networks and Signal Processing**, 2003. Proceedings of the 2003, Nanjing, China, p.976-981, 2003. <http://dx.doi.org/10.1109/icnnspp.2003.1280764>.

CARRIVICK, J. L., SMITH, M. W., QUINCEY, D. J. Structure from Motion in the Geosciences. New York: Wiley-blackwell, 2016. 208 p.

CASTANHEIRA, L. G. Aplicação da mineração de dados à análise das condições de operação de transformadores. **Revista Eletrônica Produção & Engenharia**, v. 2, n. 1, p.12-23. 2009.

CHUTIA, D.; BHATTACHARYYA, D. K.; KALITA, R.; SUDHAKAR, S. OBCsvmFS: Objetc-Based Classification supported by Support Vector Machine Feature Selection approach for hyperspectral data. **Journal Geomatics**, v. 8, n. 1, 2014.

CONGALTON, R.G., GREEN, K., Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. Lweis Publishers, 1999

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, [s.l.], v. 37, n. 1, p.35-46, jul. 1991. Elsevier BV. [http://dx.doi.org/10.1016/0034-4257\(91\)90048-b](http://dx.doi.org/10.1016/0034-4257(91)90048-b).

CRUSAN, J.; GALICA, C. NASA's CubeSat Launch Initiative: Enabling broad access to space. NASA's CubeSat Launch Initiative: enabling broad access to space. **Acta Astronautica**, [S.L.], v. 157, p. 51-60, abr. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.actaastro.2018.08.048>.

DAVIS, L.A.; FILIP, L. How Long Does It Take to Develop and Launch Government Satellite Systems? International Cost Estimating and Analysis Association. **Aerospace Report**; El Segundo, CA, USA, 2015.

DHORE A. D; VEENA C. S., "Evaluation of various pansharpeneing methods using image quality metrics," 2015 2nd **International Conference on Electronics and Communication Systems** (ICECS), 2015, pp. 871-877, doi: 10.1109/ECS.2015.7125039.

DUNBAR, B. Small Spacecraft Technology. Disponível em: <https://www.nasa.gov/offices/oct/crosscutting_capability/edison/smallsat_tech.html>. Acesso em: 25 jan. 2019.

EOPORTAL. Planet - Flock Imaging Constellation. Disponível em: <<https://eoportal.org/web/eoportal/satellite-missions/f/flock-1>>. Acesso em: 24 dez. 2020.

ESPER, J.; PANETTA, P.V.; RYSCHKEWITSCH, M.; WISCOMBE, W.; NEECK, S. NASA-GSFC Nano-satellite technology for Earth Science missions. **Acta Astronautica**. 2000, 46, 287–296. [https://doi.org/10.1016/S0094-5765\(99\)00214-3](https://doi.org/10.1016/S0094-5765(99)00214-3).

FERNANDES, M. R.; AGUIAR, F. C.; SILVA, J. M.N.; FERREIRA, M. T.; PEREIRA, J. M. C. Optimal attributes for the object based detection of giant reed in riparian habitats: A comparative study between Airborne High Spatial Resolution and WorldView-2 imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 31, p. 79-91, 2014.

FITZPATRICK, B. P. Unmanned Aerial Systems for Surveying and Mapping: Cost Comparison of UAS versus Traditional Methods of Data Acquisition. 2015. Tese de Doutorado. University of Southern California.

FREITAS, M. W. D. Estudo integrado e modelagem da dinâmica da paisagem no Alto Uruguai (RS-SC). 2013. 149 f. Tese (Doutorado) - Curso de Sensoriamento Remoto, Inpe, São José dos Campos - SP, 2013.

FRIEDL, M.A.; BRODLEY, C. E. Decision tree classification of land cover from remotely sensed data. **Remote Sensing of Environment**, v.61, p.399-409, 1997.

GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R. *Random Forests* for land cover classification. **Pattern Recognition Letters**, [S.L.], v. 27, n. 4, p. 294-300, mar. 2006. Elsevier BV. <http://dx.doi.org/10.1016/j.patrec.2005.08.011>.

HALL, O.; DAHLIN, S .; MARSTORP, H .; ARCHILA BUSTOS, M .; ÖBORN, I .; JIRSTRÖM, M. Classification of Maize in Complex Smallholder Farming Systems Using UAV Imagery. **Drones**, [S.L.], v. 2, n. 3, p. 22, 22 jun. 2018. MDPI AG. <http://dx.doi.org/10.3390/drones2030022>.

HAMEDIANFAR, A.; SHAFRI, H. Z. M.; MANSOR, S.; AHMAD, N. Combining data mining algorithm and object-based image analysis for detailed urban mapping of hyperspectral images. **Journal Of Applied Remote Sensing**, [S.L.], v. 8, n. 1, p. 085091, 27 ago. 2014. SPIE-Intl Soc Optical Eng. <http://dx.doi.org/10.1117/1.jrs.8.085091>.

HAND, D; MANNILA, H; SMYTH, P. Principles of Data Mining. MIT Press, 2001.

HARALICK R. M., SHANMUGAM, K. e DINSTEIN, I. "Textural Features for Image Classification," in **IEEE Transactions on Systems, Man, and Cybernetics**, vol. SMC-3, no. 6, pp. 610-621, Nov. 1973, doi: 10.1109/TSMC.1973.4309314.

HAY, G. J., CASTILLA, G. Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. In: *Object-based image analysis*. Springer, Berlin, Heidelberg, 2008. p. 75-89.

HOUBORG, R.; MCCABE, M.F. High-Resolution NDVI from Planet's Constellation of Earth Observing Nano-Satellites: a new data source for precision agriculture. **Remote Sensing**, [S.L.], v. 8, n. 9, p. 768, 19 set. 2016. MDPI AG. <http://dx.doi.org/10.3390/rs8090768>.

JAMES, M. R.; ROBSON, S. Mitigating systematic error in topographic models derived from UAV and ground-based image networks. **Earth Surface Processes and Landforms**, [s.l.], v. 39, n. 10, p.1413-1420, 19 jun. 2014. Wiley. <http://dx.doi.org/10.1002/esp.3609>.

JENEROWICZ, A.; WOROSZKIEWICZ, M. The pan-sharpening of satellite and UAV imagery for agricultural applications. **Remote Sensing for Agriculture, Ecosystems, and Hydrology XVIII**; Neale, CMU, Maltese, A., Eds .; Spie-Int Soc Optical Engineering: Bellingham, DC, EUA, 2016; Volume 9998.

JENSEN, J. R. Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. São José dos Campos: Parêntese, 2011. 598 p.

KUHN, M., QUINLAN, R e C5.0 Decision Trees and Rule-Based Models, disponível em: < <https://cran.rstudio.com/web/packages/C50/C50.pdf>>. Acesso em: 10 de Agosto de 2021.

KWAK, G.; PARK, N. Impact of Texture Information on Crop Classification with Machine Learning and UAV Images. **Applied Sciences**, [S.L.], v. 9, n. 4, p. 643, 14 fev. 2019. MDPI AG. <http://dx.doi.org/10.3390/app9040643>. LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for category data. *Biometrics*, 33(1), p.159-174. 1977.

LATIF, M. A. An Agricultural Perspective on Flying Sensors: state of the art, challenges, and future directions. **Ieee Geoscience And Remote Sensing Magazine**, [S.L.], v. 6, n. 4, p. 10-22, dez. 2018. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/mgrs.2018.2865815>.

LECHNER, A. M.; FLETCHER, A.; JOHANSEN, K.; ERSKINE, P. Characterising 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*, vol. 6, p. 101-106, 2012.

LIU, S., LI, H., ZHANG, Y., ZOU, B. AND ZHAO, J. *Random Forest-based track initiation method. The Journal of Engineering*, 2019: 6175-6179. <https://doi.org/10.1049/joe.2019.0180>

LOWE, D. G. Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision*, Vancouver, p.1-28, fev. 2004. Disponível em: <<http://www.cs.berkeley.edu/~malik/cs294/lowe-ijcv04.pdf>>. Acesso em: 05 jan. 2021.

MADAWALAGAMA S.L., MUNASINGHE N., DAMPEGAMA, S.D.P.J., SAMARAKOON L. Low cost Aerial Mapping with consumer grade drones. In: *37th Asian Conference on Remote Sensing*. 2016.

MICHELETTI, N.; CHANDLER, J. H.; LANE, S. N.. Investigating the geomorphological potential of freely available and accessible structure-from-motion photogrammetry using a smartphone. *Earth Surface Processes and Landforms*, [s.l.], v. 40, n. 4, p.473-486, 11 out. 2014. Wiley. <http://dx.doi.org/10.1002/esp.3648>.

MIRANDA, V., PINA, P., HELENO, S., VIEIRA, G., MORA, C., & SCHAEFER, C.E.G.R. Monitoring recent changes of vegetation in Fildes Peninsula (King George Island, Antarctica) through satellite imagery guided by UAV surveys. *Science of The Total Environment*, v. 704, p. 135295, 2020.

MORAES, S. R. Abordagem GEOBIA para a classificação do uso e cobertura da terra em área urbana associadas ao desenvolvimento de framework para monitoramento de inundações no município de Lajeado – RS. Dissertação (Mestrado). Universidade federal do Rio Grande do sul. UFRGS. Dissertação de Mestrado. 2018.

MOREIRA, M. A. Fundamentos do sensoriamento remoto e metodologias de aplicação. São José dos Campos, 2001. *Instituto Nacional de Pesquisas Espaciais (INPE)*. 208p.

MOTA, A. A. L. Previsão de prêmio e a ocorrência de sinistros no mercado de seguro agrícola brasileiro. Dissertação (Mestrado) – Escola Superior de Agricultura “Luiz de Queiroz” – 2019.

MOUNTRAKIS, G.; I.M, J.; OGOLE, C. Support vector machines in remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 3, p. 247-259, 2011.

MYBURGH, G., NIEKERK, A. V. Effect of a Feature Dimensionality on Object-based Land Cover Classification: A comparison of Three Classifiers. 2013. **South African of Geomatics**. v.2, n. 1, P. 13-28, 2013.

OUÉDRAOGO, M. M. DEGRÉ. A, DEBOUCHE, C. LISEIN, J. The evaluation of unmanned aerial system-based photogrammetry and terrestrial laser scanning to generate DEMs of agricultural watersheds, **Geomorphology**. 2014. Pages 339-355, ISSN 0169-555X, <https://doi.org/10.1016/j.geomorph.2014.02.016>.

PAJARES, G. Overview and Current Status of Remote Sensing Applications Based on Unmanned Aerial Vehicles (UAVs). **Photogrammetric Engineering & Remote Sensing**, [S.L.], v. 81, n. 4, p. 281-330, 1 abr. 2015. American Society for Photogrammetry and Remote Sensing. <http://dx.doi.org/10.14358/pers.81.4.281>.

PLANET. Our Approach. 2018b. Disponível em: <<https://www.planet.com/company/>>. Acesso em: 15 dez. 2020

PLANET. Planet Imagery: Product Specifications. San Francisco, Ca: Planet, 2018a. 57 p. Disponível em: <https://www.planet.com/products/satellite-imagery/files/Planet_Combined_Imagery_Product_Specs_Decemb>. Acesso em: 15 dez. 2020.

PLANET. Planet Surface Reflectance Product. San Francisco, Ca: Planet, 2018c. 57 p. Disponível em: <https://assets.planet.com/marketing/PDF/Planet_Surface_Reflectance_Technical_White_Paper.pdf>. Acesso em: 15 dez 2020.

PONTIUS, R. G.; MILLONES, M. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal Of Remote Sensing**, [S.L.], v. 32, n. 15, p. 4407-4429, 10 ago. 2011. Informa UK Limited. <http://dx.doi.org/10.1080/01431161.2011.552923>.

POWERS, R. P.; HERMOSILLA, T., COOPS, N. C.; CHEN, G. Remote sensing and object-based techniques for mapping fine-scale industrial disturbances. **International Journal Of Applied Earth Observation And Geoinformation**, [S.L.], v. 34, p. 51-57, fev. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.jag.2014.06.015>

PRENTICE, R. M.; PECIÑA, M. V.; WARD, R. D.; BERGAMO, T. F.; JOYCE, C. B.; SEPP, K. Machine Learning Classification and Accuracy Assessment from High-Resolution Images of Coastal Wetlands. **Remote Sensing**, [S.L.], v. 13, n. 18, p. 3669, 14 set. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13183669>.

REMONDINO, F.; SPERA, M.G.; NOCERINO, E.; MENNA, F.; NEX, F.C. State of the art in high density image matching. **The Photogrammetric Record**, [S.L.], v. 29, n. 146, p. 144-166, jun. 2014. Wiley. <http://dx.doi.org/10.1111/phor.12063>.

RODRIGUES, E. L. S. Estudo sobre a fisiologia da paisagem do areal do Cerro da Esquina no município de São Francisco de Assis - RS. 2018. 153 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Geografia. Geociências, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2018.

RUIZ, L. C, GUASSELLI, L. A, CATEN A. T Árvore de decisão e análise baseada em objetos na classificação de imagens com resolução espacial submétrica adquiridas por VANT. 2017. BCG - **Boletim de Ciências Geodésicas** - On-Line version, <http://dx.doi.org/10.1590/S1982-21702017000200016>.

RUIZ, L.F.C. Uma abordagem de classificação da cobertura da terra em imagens obtidas por veículo aéreo não tripulado. Dissertação (mestrado). Porto Alegre: UFRGS Universidade Federal do Rio Grande do Sul. 105 p. 2015.

SANDAU, R. Status and Trends of Small Satellite Missions for Earth Observation. **Acta Astronautica**, [s.l.], v. 66, n. 1-2, p.1-12, jan. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.actaastro.2009.06.008>.

SELVA, D.; KREJCI, D. A Survey and Assessment of the Capabilities of Cubesats for Earth Observation. **Acta Astronautica**, [s.l.], v. 74, p.50-68, maio 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.actaastro.2011.12.014>.

SHAHBAZI, M; THÉAU, J.; MÉNARD, P. Recent applications of unmanned aerial imagery in natural resource management. **Giscience & Remote Sensing**, [S.L.], v. 51, n. 4, p. 339-365, 20 jun. 2014. Informa UK Limited. <http://dx.doi.org/10.1080/15481603.2014.926650>.

SWARTWOUT, M. The First One Hundred CubeSats: A Statistical Look. *Journal of Small Satellites*, Hampton, Virginia, v. 2, n. 2, p.213-233, 2 dez. 2013. Mensal. Disponível em: <<http://www.jossonline.com/wp-content/uploads/2014/12/0202-The-First-OneHundred-Cubesats.pdf>>. Acesso em: 30 abr. 2021

TEDESCO, A; ANTUNES, A. F. B; OLIANI, L. O. Detecção de formação erosiva (voçoroca) por meio de classificação hierárquica e por árvore de decisão. **Boletim de Ciências Geodésicas**, [s.l.], v. 20, n. 4, p.1005-1026, dez. 2014. FapUNIFESP (SciELO).

TEMING T.; YUH-CHI L.; CHIEN-PING C.; PING S. H. Adjustable intensity-hue-saturation and Brovey transform fusion technique for IKONOS/QuickBird imagery. **Optical Engineering** 44(11), 116201 (1 November 2005). <https://doi.org/10.1117/1.2124871>

TOMMASELLI, A. M. G. Fotogrametria básica. UNESP: Departamento de Cartografia, 2009 (Apostila).

TOTH, C; JÓZKÓW, G. Remote Sensing Platforms and Sensors: A survey. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s.l.], v. 115, p.22-36, maio 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.isprsjprs.2015.10.004>.

TURNER, D.; LUCIEER, A.; WATSON, C. An automated technique for generating georectified mosaics from ultra-high resolution unmanned aerial vehicle (UAV) imagery, based on Structure From Motion (SFM) point clouds. **Remote Sensing**, vol. 4, n. 5, p. 1392-1410, 2012

VAPNIK, V. The nature of statistical learning theory. **Springer science & business media**, 2013.

WALD, L. Data Fusion. Definitions and Architectures - Fusion of Images of Different Spatial Resolutions. 2002. École des Mines, Paris. Disponível em: <https://www.researchgate.net/publication/280892682_Data_Fusion_Definitions_and_Architectures_-_Fusion_of_Images_of_Different_Spatial_Resolutions>. Acesso em: 22 jan. 2021.

WALKER, M. *Random Forest* Algorithm. 2013. Disponível em: <<http://www.datasciencecentral.com/profiles/blogs/random-Forest-algorithm>>. Acesso em: 26 jan. 2021.

WALLACE, L.; LUCIEER, A.; MALENOVSKÝ, Z.; TURNER, D.; VOPĚNKA, P. Assessment of Forest Structure Using Two UAV Techniques: a comparison of airborne laser scanning and structure from motion (sfm) point clouds. **Forests**, [S.L.], v. 7, n. 12, p. 62, 7 mar. 2016. MDPI AG. <http://dx.doi.org/10.3390/f7030062>.

WULDER, M.A.; MASEK, J.G.; COHEN, W.B.; LOVELAND, T.R.; WOODCOCK, C.E. Opening the archive: how free data has enabled the science and monitoring promise of landsat. **Remote Sensing Of Environment**, [S.L.], v. 122, p. 2-10, jul. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2012.01.010>.

YAN, G.; MAS, J.-F.; MAATHUIS, B.H.P.; XIANGMIN, Z.; VAN DIJK, P.M. Comparison of pixel-based and object-oriented image classification approaches—a case study in a coal fire area, Wuda, Inner Mongolia, China. **International Journal Of Remote Sensing**, [S.L.], v. 27, n. 18, p. 4039-4055, set. 2006. Informa UK Limited. <http://dx.doi.org/10.1080/01431160600702632>.

YILMAZ, V., GUNGOR, O. Fusion of very high-resolution UAV images with criteria-based image fusion algorithm. **Arabian Journal of Geosciences** 9, 59. 2016. <https://doi.org/10.1007/s12517-015-2109-8>.

YU, Q., GONG, P., CLINTON, N., BIGING, G., KELLY, M., & SCHIROKAUER, D. Objectbased detailed vegetation classification with airborne high spatial resolution remote sensing imagery. **Photogrammetric Engineering & Remote Sensing**, v. 72, n. 7, p. 799-811, 2006.

ZHAO, L.; SHI, Y.; LIU, B.; HOVIS, C.; DUAN, Y.; SHI, Z. Finer Classification of Crops by Fusing UAV Images and Sentinel-2A Data. **Remote Sensing**, [S.L.], v. 11, n. 24, p. 3012, 14 dez. 2019. MDPI AG. <http://dx.doi.org/10.3390/rs11243012>.

ZHU, Z.; WULDER, M.A.; Roy, D.P.; WOODCOCK, C.E.; HANSEN, M.C.; RADELOFF, V.C.; HEALEY, S.P.; SCHAAF, C.; HOSTERT, P.; STROBL, P.; *et al.* Benefits of the free and open Landsat data policy. **Remote Sensing Of Environment**, [S.L.], v. 224, p. 382-385, abr. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2019.02.016>.

8 ANEXOS

8.1 ANEXO I: Relatório dos pontos de apoio processados no *software* TOPCON TOOLS.

Project name: EEA 2018.ttp

Surveyor:

Comment:

Linear unit: Meters

Projection: UTMSouth-Zone_22 : 54W to 48W

Geoid:

| Name | Points | | Elevation (m) | Code |
|---------------|----------------------|---------------------|---------------|-----------|
| | Grid Northing (m) | Grid Easting (m) | | |
| BASE_SEDE | 6667858,637 | 434624,423 | 79,794 | |
| BASE_M3 | 6670229,917 | 434741,18 | 53,852 | BASE_GNSS |
| POAL | 6673004,054 | 488457,544 | 76,745 | |
| gcp01 | 6668234,508 | 434485,876 | 75,207 | |
| gcp002 | 6667658,59 | 434476,726 | 80,828 | |
| gcp004 | 6667773,73 | 435092,877 | 59,455 | |
| gcp_003 | 6668438,702 | 434879,237 | 73,123 | |
| gcp_008 | 6668267,264 | 435151,822 | 65,888 | |
| gcp_007 | 6667706,385 | 435927,35 | 63,504 | |
| gcp_006 | 6668029,302 | 435732,214 | 59,863 | |
| gcp_005 | 6668369,186 | 435742,399 | 52,278 | |
| log0609r_ESQO | 6667706,392 | 435927,342 | 63,555 | |

Adjustment

Control Tie Analysis: success

Adjustment type: Plane + Height, Constraint

Confidence level: 95 %

Number of adjusted points: 12

Number of plane control points: 3

Number of plane weighted points: 1

Number of used GPS vectors: 31

Number of rejected GPS vectors by plane: 10

A posteriori plane or 3D UWE: 1,045683 , Bounds: (0,7187953 , 1,280625)

Number of height control points: 3

Number of height weighted points: 1

Number of rejected GPS vectors by height: 8

A posteriori height UWE: 1,440462 , Bounds: (0,6341473 , 1,365911)

| Name | GPS Observations | | | | |
|-------------------------|------------------|------------|---------|--------------|--------------|
| | dN (m) | dE (m) | dHt (m) | Horz RMS (m) | Vert RMS (m) |
| BASE_SEDE-BASE_M3 | 2371,279 | 116,758 | -25,943 | 0,001 | 0,002 |
| BASE_SEDE-POAL | 5145,42 | 53833,123 | -3,042 | 0,018 | 0,03 |
| BASE_SEDE-gcp01 | 375,872 | -138,547 | -4,582 | 0,002 | 0,003 |
| BASE_SEDE-gcp002 | -200,048 | -147,698 | 1,026 | 0,001 | 0,002 |
| BASE_SEDE-gcp004 | -84,903 | 468,458 | -20,333 | 0,002 | 0,004 |
| BASE_SEDE-gcp_003 | 580,065 | 254,814 | -6,669 | 0,001 | 0,002 |
| BASE_SEDE-gcp_008 | 408,629 | 527,398 | -13,902 | 0,001 | 0,002 |
| BASE_SEDE-gcp_007 | -152,251 | 1302,928 | -16,29 | 0,004 | 0,007 |
| BASE_SEDE-gcp_006 | 170,665 | 1107,791 | -19,931 | 0,002 | 0,004 |
| BASE_SEDE-gcp_005 | 510,55 | 1117,976 | -27,516 | 0,004 | 0,008 |
| BASE_SEDE-log0609r_ESQO | -152,247 | 1302,916 | -16,241 | 0,014 | 0,025 |
| BASE_M3-POAL | 2774,135 | 53716,362 | 22,886 | 0,017 | 0,03 |
| BASE_M3-gcp01 | -1995,409 | -255,304 | 21,352 | 0,001 | 0,002 |
| BASE_M3-gcp002 | -2571,325 | -264,453 | 26,985 | 0,001 | 0,002 |
| BASE_M3-gcp004 | -2456,186 | 351,697 | 5,602 | 0,002 | 0,005 |
| BASE_M3-gcp_003 | -1791,215 | 138,059 | 19,265 | 0,002 | 0,005 |
| BASE_M3-gcp_008 | -1962,657 | 410,641 | 12,03 | 0,001 | 0,002 |
| BASE_M3-gcp_007 | -2523,546 | 1186,012 | 9,756 | 0,066 | 0,06 |
| BASE_M3-gcp_006 | -2200,62 | 990,967 | 6,03 | 0,062 | 0,056 |
| BASE_M3-gcp_005 | -1860,558 | 1001,448 | -1,414 | 0,27 | 0,238 |
| BASE_M3-log0609r_ESQO | -2523,523 | 1186,165 | 9,705 | 0,013 | 0,022 |
| POAL-gcp01 | -4769,543 | -53971,668 | -1,523 | 0,117 | 0,169 |
| POAL-gcp002 | -5345,458 | -53980,822 | 4,088 | 0,107 | 0,196 |
| POAL-gcp004 | -5230,235 | -53364,874 | -17,497 | 0,164 | 0,123 |
| POAL-gcp_003 | -4565,734 | -53578,714 | -3,76 | 0,086 | 0,172 |
| POAL-gcp_008 | -4736,875 | -53305,633 | -10,582 | 0,091 | 0,165 |
| POAL-gcp_007 | -5297,4 | -52529,869 | -12,634 | 0,698 | 0,663 |
| POAL-gcp_006 | -4974,773 | -52725,35 | -16,957 | 0,104 | 0,095 |
| POAL-gcp_005 | -4634,672 | -52715,216 | -23,944 | 0,154 | 0,133 |
| POAL-log0609r_ESQO | -5298,698 | -52529,541 | -14,066 | 1,046 | 1,114 |
| gcp004-gcp_008 | 493,535 | 58,945 | 6,434 | 0,001 | 0,002 |

GPS Occupations

| Point Name | Original Name |
|-------------------|----------------------|
| gcp_003 | gcp_003 |
| gcp_008 | gcp_008 |
| log0609r_ESQO | O |
| gcp_007 | gcp_007 |
| gcp_006 | gcp_006 |
| gcp_005 | gcp_005 |
| gcp01 | gcp01 |
| gcp002 | gcp002 |
| gcp004 | gcp004 |
| BASE_SEDE | BASE_SEDE |
| BASE_M3 | BASE_M3 |
| POAL | POAL |

| Name | Point Summary | | | Code |
|---------------|------------------------------|-----------------------------|----------------------|-------------|
| | Grid Northing (m) | Grid Easting (m) | Elevation (m) | |
| BASE_SEDE | 6667858,637 | 434624,423 | 79,794 | |
| BASE_M3 | 6670229,917 | 434741,18 | 53,852 | BASE_GNSS |
| POAL | 6673004,054 | 488457,544 | 76,745 | |
| gcp01 | 6668234,508 | 434485,876 | 75,207 | |
| gcp002 | 6667658,59 | 434476,726 | 80,828 | |
| gcp004 | 6667773,73 | 435092,877 | 59,455 | |
| gcp_003 | 6668438,702 | 434879,237 | 73,123 | |
| gcp_008 | 6668267,264 | 435151,822 | 65,888 | |
| gcp_007 | 6667706,385 | 435927,35 | 63,504 | |
| gcp_006 | 6668029,302 | 435732,214 | 59,863 | |
| gcp_005 | 6668369,186 | 435742,399 | 52,278 | |
| log0609r_ESQO | 6667706,392 | 435927,342 | 63,555 | |

8.2 ANEXO II: Relatório de processamento fotogramétrico realizado no software Agisoft Metashape

09 DE JUNHO DE 2018



Survey Data

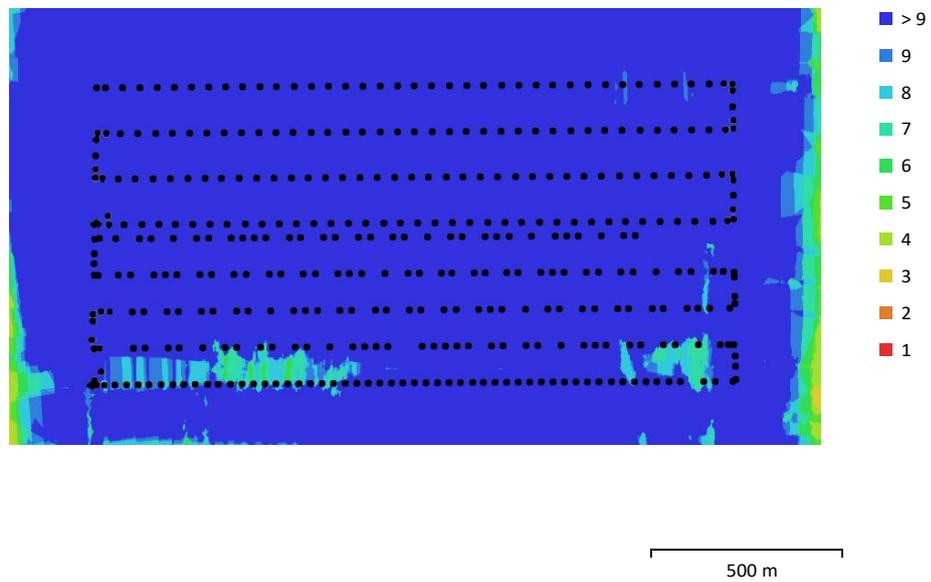


Fig. 1. Camera locations and image overlap.

| | | | |
|--------------------|----------------------|---------------------|-----------|
| Number of images: | 390 | Camera stations: | 389 |
| Flying altitude: | 206 m | Tie points: | 279,707 |
| Ground resolution: | 7.69 cm/pix | Projections: | 1,378,945 |
| Coverage area: | 2.13 km ² | Reprojection error: | 0.973 pix |

Table 1. Cameras.

| Camera Model | Resolution | Focal Length | Pixel Size | Precalibrated |
|------------------|-------------|--------------|---------------------|---------------|
| FC300X (3.61 mm) | 4000 x 3000 | 3.61 mm | 1.56 x 1.56 μ m | No |

Camera Calibration

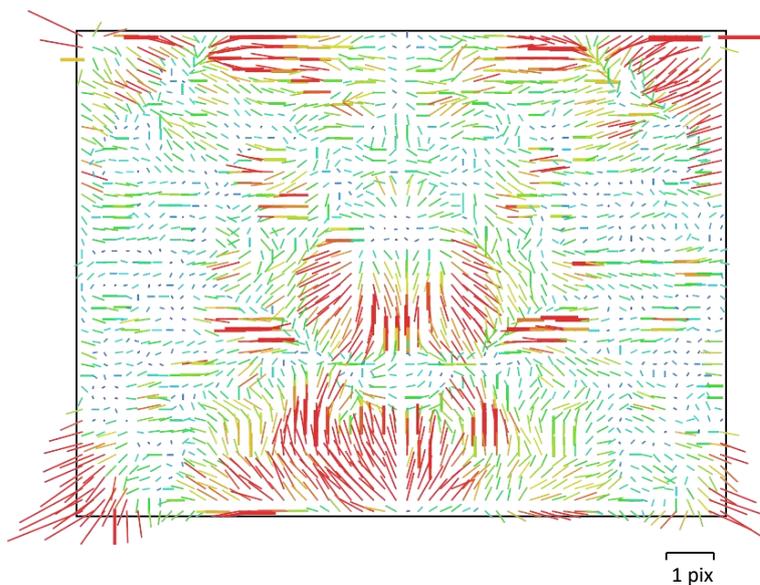


Fig. 2. Image residuals for FC300X (3.61 mm).

FC300X (3.61 mm)

390 images

| | | | |
|-------|--------------------|----------------|---|
| Type | Resolution | Focal Length | Pixel Size |
| Frame | 4000 x 3000 | 3.61 mm | 1.56 x 1.56 μm |

| | Value | Error | F | Cx | Cy | K1 | K2 | K3 | P1 | P2 |
|-----------|----------------------|----------|------|-------|-------|-------|-------|-------|-------|-------|
| F | 2346.54 | 1 | 1.00 | -0.69 | -0.20 | -0.35 | 0.34 | 0.22 | -0.09 | 0.16 |
| Cx | 10.1307 | 0.068 | | 1.00 | 0.15 | 0.24 | -0.23 | -0.16 | 0.27 | -0.12 |
| Cy | 27.5427 | 0.046 | | | 1.00 | 0.07 | -0.06 | -0.04 | 0.00 | 0.19 |
| K1 | -0.0123914 | 3e-005 | | | | 1.00 | -0.97 | 0.75 | 0.04 | -0.03 |
| K2 | 0.0119247 | 6.2e-005 | | | | | 1.00 | -0.83 | -0.04 | 0.03 |
| K3 | 0.00309647 | 3.8e-005 | | | | | | 1.00 | -0.01 | 0.06 |
| P1 | -1.72428e-006 | 2.4e-006 | | | | | | | 1.00 | -0.05 |
| P2 | 0.0008663 | 2.3e-006 | | | | | | | | 1.00 |

Table 2. Calibration coefficients and correlation matrix.

Ground Control Points

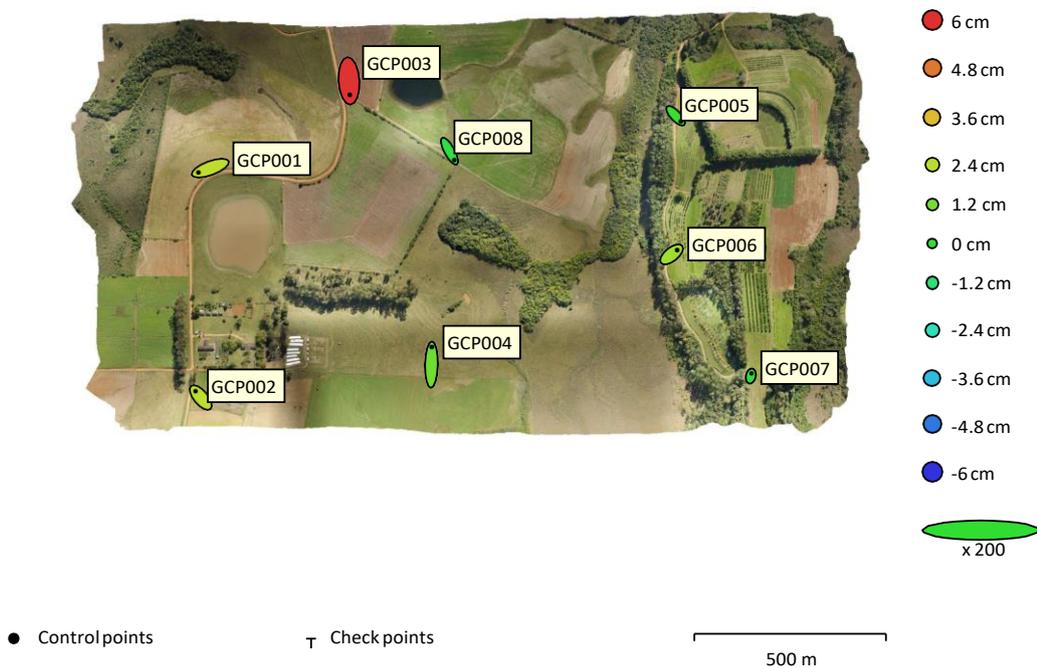


Fig. 3. GCP locations and error estimates.

Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.
 Estimated GCP locations are marked with a dot or crossing.

| Count | X error (cm) | Y error (cm) | Z error (cm) | XY error (cm) | Total (cm) |
|-------|--------------|--------------|--------------|---------------|------------|
| 8 | 13.9626 | 23.7772 | 2.56843 | 27.5737 | 27.693 |

Table 3. Control points RMSE.
 X - Easting, Y - Northing, Z - Altitude.

| Label | X error (cm) | Y error (cm) | Z error (cm) | Total (cm) | Image (pix) |
|--------------|----------------|----------------|----------------|---------------|--------------|
| GCP001 | -29.4751 | -11.21 | 2.45829 | 31.6305 | 0.741 (20) |
| GCP002 | -13.0737 | 15.9962 | 2.45029 | 20.8039 | 0.605 (13) |
| GCP003 | 2.04289 | -35.5416 | 5.98192 | 36.0994 | 0.560 (10) |
| GCP004 | 0.879273 | 44.8628 | 1.0491 | 44.8837 | 0.581 (16) |
| GCP005 | 12.79 | -14.3461 | 0.182023 | 19.2205 | 0.593 (19) |
| GCP006 | 14.0033 | 10.2988 | 1.92215 | 17.4886 | 0.615 (14) |
| GCP007 | 1.50938 | 6.93724 | -0.102747 | 7.10028 | 0.959 (15) |
| GCP008 | 12.3706 | -22.4812 | -0.324598 | 25.662 | 0.682 (17) |
| Total | 13.9626 | 23.7772 | 2.56843 | 27.693 | 0.684 |

Table 4. Control points.

X - Easting, Y - Northing, Z - Altitude.

Digital Elevation Model

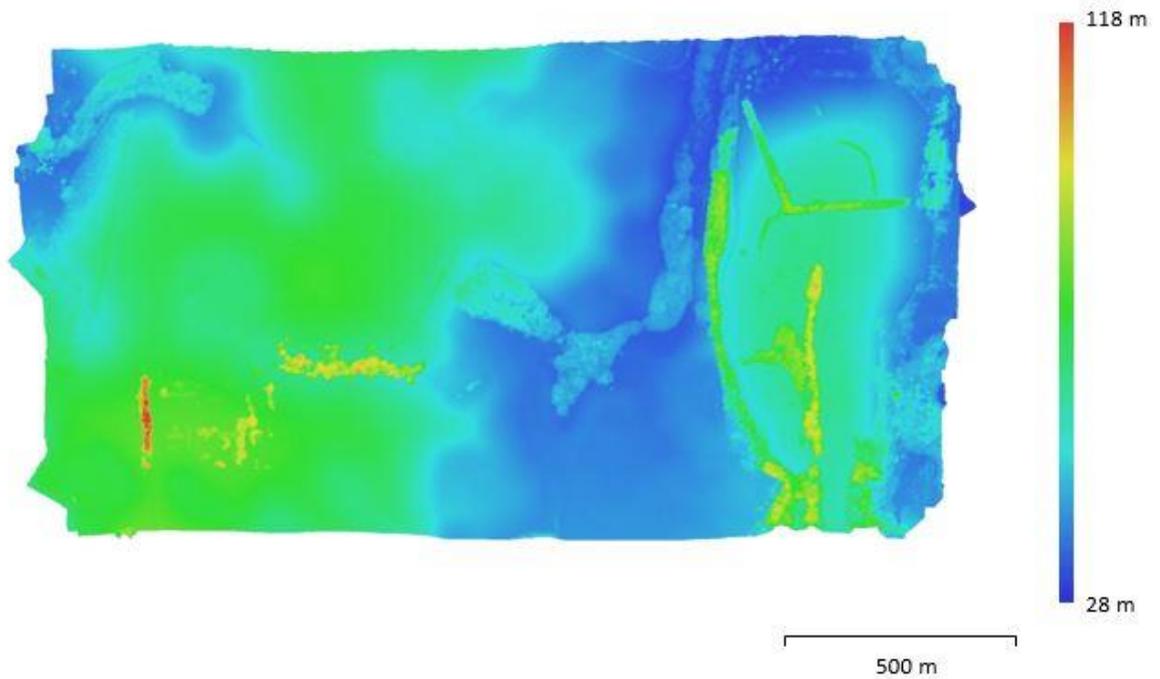


Fig. 4. Reconstructed digital elevation model.

Resolution: 15.4 cm/pix

Point density: 42.3 points/m²

Processing Parameters

| | |
|--|-------------------------------------|
| General | |
| Cameras | 390 |
| Aligned cameras | 389 |
| Markers | 8 |
| Coordinate system | WGS 84 / UTM zone 22S (EPSG::32722) |
| Rotation angles | Yaw, Pitch, Roll |
| Point Cloud | |
| Points | 279,707 of 316,818 |
| RMS reprojection error | 0.419263 (0.97286 pix) |
| Max reprojection error | 2.20074 (27.4805 pix) |
| Mean key point size | 2.3251 pix |
| Point colors | 3 bands, uint8 |
| Key points | No |
| Average tie point multiplicity | 5.30184 |
| Alignment parameters | |
| Accuracy | Highest |
| Generic preselection | Yes |
| Reference preselection | Yes |
| Key point limit | 40,000 |
| Tie point limit | 4,000 |
| Adaptive camera model fitting | No |
| Matching time | 46 minutes 39 seconds |
| Alignment time | 5 minutes 20 seconds |
| Optimization parameters | |
| Parameters | f, cx, cy, k1-k3, p1, p2 |
| Optimization time | 12 seconds |
| Dense Point Cloud | |
| Points | 113,521,140 |
| Point colors | 3 bands, uint8 |
| Depth maps generation parameters | |
| Quality | High |
| Filtering mode | Aggressive |
| Processing time | 6 hours 5 minutes |
| Dense cloud generation parameters | |
| Processing time | 50 minutes 30 seconds |
| Model | |
| Faces | 90,000 |
| Vertices | 45,193 |
| Vertex colors | 3 bands, uint8 |
| Reconstruction parameters | |
| Surface type | Arbitrary |
| Source data | Sparse cloud |
| Interpolation | Enabled |
| Processing time | 7 seconds |
| DEM | |
| Size | 16,827 x 10,030 |
| Coordinate system | WGS 84 / UTM zone 22S (EPSG::32722) |
| Reconstruction parameters | |
| Source data | Dense cloud |
| Interpolation | Enabled |

8.3 ANEXO III: Tabelas de acurácias das classificações

Tabela 7 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo *Random Forest* para o conjunto 1

| Classe de Uso da Terra | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | Total Classificado | |
|---------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------------------|--------|
| 1 - Mata | 102 | 9 | 1 | 0 | 1 | 0 | 2 | 22 | 0 | 1 | 6 | 0 | 7 | 0 | 151 | |
| 2 - Campo Sujo | 11 | 71 | 12 | 7 | 6 | 6 | 2 | 8 | 0 | 3 | 0 | 5 | 0 | 0 | 131 | |
| 3 - Campo Limpo II | 17 | 9 | 42 | 2 | 2 | 0 | 2 | 5 | 0 | 1 | 0 | 1 | 2 | 0 | 83 | |
| 4 - Solo Exposto | 0 | 4 | 0 | 126 | 1 | 1 | 1 | 1 | 0 | 1 | 0 | 6 | 5 | 0 | 146 | |
| 5 - Cultivo | 1 | 0 | 0 | 1 | 112 | 7 | 3 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 125 | |
| 6 - Campo Limpo I | 4 | 1 | 1 | 0 | 15 | 79 | 12 | 5 | 0 | 0 | 0 | 1 | 0 | 0 | 118 | |
| 7 - Pastagem | 2 | 1 | 0 | 0 | 27 | 4 | 39 | 1 | 0 | 0 | 0 | 1 | 0 | 0 | 75 | |
| 8 - Pomar | 26 | 5 | 2 | 0 | 3 | 1 | 0 | 57 | 0 | 2 | 2 | 0 | 1 | 1 | 100 | |
| 9 - Açude | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 57 | 0 | 1 | 0 | 0 | 1 | 60 | |
| 10 - Açude Eutrofizado | 1 | 0 | 0 | 4 | 2 | 0 | 0 | 0 | 0 | 44 | 0 | 0 | 4 | 0 | 55 | |
| 11 - Sombra | 6 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 69 | 0 | 0 | 0 | 75 | |
| 12 - Estrada | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 37 | 0 | 0 | 37 | |
| 13 - Edificação | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 27 | 4 | 33 | |
| 14 - Silo | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 5 | 31 | 36 | |
| Total pontos de checagem | 170 | 100 | 58 | 143 | 169 | 98 | 61 | 100 | 57 | 52 | 78 | 51 | 51 | 37 | 1225 | |
| Acurácia do Produtor | 0,6000 | 0,7100 | 0,7241 | 0,8811 | 0,6627 | 0,8061 | 0,6393 | 0,5700 | 1,0000 | 0,8462 | 0,8846 | 0,7255 | 0,5294 | 0,8378 | Exatidão global | 0,7290 |
| Acurácia do Usuário | 0,6755 | 0,5420 | 0,5060 | 0,8630 | 0,8960 | 0,6695 | 0,5200 | 0,5700 | 0,9500 | 0,8000 | 0,9200 | 1,0000 | 0,8182 | 0,8611 | Índice Kappa | 0,7035 |

Tabela 8 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo *Random Forest* para o conjunto 2

| Classe de Uso da Terra | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | Total Classificado | |
|---------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------------------|--------|
| 1 - Mata | 99 | 10 | 1 | 0 | 1 | 0 | 3 | 20 | 0 | 1 | 6 | 0 | 7 | 1 | 149 | |
| 2 - Campo Sujo | 15 | 67 | 12 | 6 | 4 | 7 | 2 | 9 | 0 | 3 | 0 | 3 | 1 | 0 | 129 | |
| 3 - Campo Limpo II | 16 | 12 | 42 | 2 | 3 | 0 | 1 | 5 | 0 | 1 | 0 | 0 | 2 | 0 | 84 | |
| 4 - Solo Exposto | 0 | 5 | 0 | 128 | 2 | 0 | 0 | 1 | 0 | 1 | 0 | 6 | 4 | 0 | 147 | |
| 5 - Cultivo | 2 | 0 | 0 | 1 | 114 | 8 | 3 | 1 | 0 | 0 | 0 | 1 | 1 | 0 | 131 | |
| 6 - Campo Limpo I | 3 | 0 | 1 | 0 | 12 | 77 | 13 | 5 | 0 | 0 | 0 | 2 | 0 | 0 | 113 | |
| 7 - Pastagem | 2 | 1 | 0 | 0 | 27 | 5 | 37 | 2 | 0 | 0 | 0 | 1 | 0 | 0 | 75 | |
| 8 - Pomar | 27 | 5 | 2 | 0 | 4 | 1 | 1 | 57 | 0 | 2 | 1 | 0 | 0 | 0 | 100 | |
| 9 - Açude | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 57 | 0 | 1 | 0 | 0 | 1 | 60 | |
| 10 - Açude eutrofizado | 1 | 0 | 0 | 4 | 2 | 0 | 0 | 0 | 0 | 44 | 0 | 0 | 4 | 0 | 55 | |
| 11 - Sombra | 5 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 70 | 0 | 0 | 0 | 75 | |
| 12 - Estrada | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 38 | 1 | 0 | 40 | |
| 13 - Edificação | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 26 | 3 | 30 | |
| 14 - Silo | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 5 | 32 | 37 | |
| Total pontos de checagem | 170 | 100 | 58 | 143 | 169 | 98 | 61 | 100 | 57 | 52 | 78 | 51 | 51 | 37 | 1225 | |
| Acurácia do Produtor | 0,5824 | 0,6700 | 0,7241 | 0,8951 | 0,6746 | 0,7857 | 0,6066 | 0,5700 | 1,0000 | 0,8462 | 0,8974 | 0,7451 | 0,5098 | 0,8649 | Exatidão global | 0,6990 |
| Acurácia do Usuário | 0,6644 | 0,5194 | 0,5000 | 0,8707 | 0,8702 | 0,6814 | 0,4933 | 0,5700 | 0,9500 | 0,8000 | 0,9333 | 0,9500 | 0,8667 | 0,8649 | Índice Kappa | 0,7249 |

Tabela 9 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo *Random Forest* para o conjunto 3

| Classe de Uso da Terra | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | Total Classificado | |
|---------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------------------|--------|
| 1 - Mata | 155 | 1 | 1 | 0 | 0 | 0 | 0 | 18 | 0 | 0 | 4 | 0 | 0 | 0 | 179 | |
| 2 - Campo Sujo | 1 | 82 | 11 | 5 | 2 | 3 | 0 | 3 | 0 | 0 | 0 | 3 | 0 | 0 | 110 | |
| 3- Campo Limpo II | 0 | 9 | 40 | 1 | 0 | 1 | 1 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 54 | |
| 4 - Solo Exposto | 0 | 2 | 0 | 133 | 2 | 1 | 2 | 0 | 0 | 0 | 0 | 4 | 0 | 0 | 144 | |
| 5 - Cultivo | 0 | 0 | 4 | 3 | 147 | 8 | 6 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 170 | |
| 6 - Campo Limpo I | 0 | 0 | 2 | 0 | 10 | 83 | 6 | 3 | 0 | 0 | 0 | 2 | 0 | 0 | 106 | |
| 7 - Pastagem | 0 | 0 | 0 | 0 | 7 | 1 | 46 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 54 | |
| 8 - Pomar | 6 | 6 | 0 | 0 | 0 | 0 | 0 | 73 | 0 | 2 | 2 | 4 | 0 | 0 | 93 | |
| 9 - Açude | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 57 | 0 | 1 | 0 | 0 | 1 | 60 | |
| 10 - Açude Eutrofizado | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 50 | 0 | 0 | 0 | 0 | 52 | |
| 11 - Sombra | 4 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 71 | 0 | 0 | 0 | 75 | |
| 12- Estrada | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 37 | 0 | 0 | 37 | |
| 13 - Edificação | 4 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 1 | 44 | 2 | 52 | |
| 14 - Silo | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 5 | 34 | 39 | |
| Total pontos de checagem | 170 | 100 | 58 | 143 | 169 | 98 | 61 | 100 | 57 | 52 | 78 | 51 | 51 | 37 | 1225 | |
| Acurácia do Produtor | 0,9118 | 0,8200 | 0,6897 | 0,9301 | 0,8698 | 0,8469 | 0,7541 | 0,7300 | 1,0000 | 0,9615 | 0,9103 | 0,7255 | 0,8627 | 0,9189 | Exatidão global | 0,8588 |
| Acurácia do Usuário | 0,8659 | 0,7455 | 0,7407 | 0,9236 | 0,8647 | 0,7830 | 0,8519 | 0,7849 | 0,9500 | 0,9615 | 0,9467 | 1,0000 | 0,8462 | 0,8718 | Índice Kappa | 0,8448 |

Tabela 10 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo *Random Forest* para o conjunto 4

| Classe de Uso da Terra | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | Total Classificado | |
|---------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------------------|--------|
| 1 - Mata | 153 | 1 | 1 | 0 | 0 | 1 | 0 | 19 | 0 | 0 | 4 | 0 | 0 | 0 | 179 | |
| 2 - Campo Sujo | 1 | 80 | 10 | 6 | 3 | 3 | 2 | 3 | 0 | 0 | 0 | 3 | 0 | 0 | 111 | |
| 3- Campo Limpo II | 0 | 10 | 42 | 1 | 0 | 1 | 1 | 3 | 0 | 0 | 0 | 0 | 0 | 0 | 58 | |
| 4 - Solo Exposto | 0 | 3 | 0 | 131 | 3 | 1 | 2 | 0 | 0 | 0 | 0 | 3 | 0 | 0 | 143 | |
| 5 - Cultivo | 0 | 0 | 4 | 4 | 151 | 6 | 5 | 0 | 0 | 0 | 0 | 1 | 2 | 0 | 173 | |
| 6 - Campo Limpo I | 0 | 0 | 1 | 0 | 6 | 85 | 7 | 4 | 0 | 0 | 0 | 2 | 0 | 0 | 105 | |
| 7 - Pastagem | 0 | 0 | 0 | 0 | 5 | 1 | 44 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 50 | |
| 8 - Pomar | 6 | 6 | 0 | 0 | 0 | 0 | 0 | 71 | 0 | 2 | 2 | 4 | 0 | 0 | 91 | |
| 9 - Açude | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 57 | 0 | 0 | 0 | 0 | 1 | 59 | |
| 10 - Açude eutrofizado | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 50 | 0 | 0 | 0 | 0 | 51 | |
| 11 - Sombra | 5 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 72 | 0 | 0 | 0 | 77 | |
| 12- Estrada | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 37 | 0 | 0 | 37 | |
| 13 - Edificação | 5 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 45 | 2 | 53 | |
| 14 - Silo | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 4 | 34 | 38 | |
| Total pontos de checagem | 170 | 100 | 58 | 143 | 169 | 98 | 61 | 100 | 57 | 52 | 78 | 51 | 51 | 37 | 1225 | |
| Acurácia do Produtor | 0,9118 | 0,8200 | 0,6897 | 0,9301 | 0,8698 | 0,8469 | 0,7541 | 0,7300 | 1,0000 | 0,9615 | 0,9103 | 0,7255 | 0,8627 | 0,9189 | Exatidão global | 0,8588 |
| Acurácia do Usuário | 0,8547 | 0,7207 | 0,7241 | 0,9161 | 0,8728 | 0,8095 | 0,8800 | 0,7802 | 0,9661 | 0,9804 | 0,9351 | 1,0000 | 0,8491 | 0,8947 | Índice Kappa | 0,8448 |

Tabela 11 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo *Random Forest* para o conjunto 5

| Classe de Uso da Terra | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | Total Classificado | |
|---------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------------------|--------|
| 1 - Mata | 155 | 1 | 1 | 0 | 0 | 0 | 0 | 18 | 0 | 0 | 4 | 0 | 0 | 0 | 179 | |
| 2 - Campo Sujo | 1 | 81 | 11 | 4 | 4 | 3 | 0 | 2 | 0 | 0 | 1 | 3 | 0 | 0 | 110 | |
| 3 - Campo Limpo II | 0 | 10 | 39 | 1 | 0 | 1 | 1 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 54 | |
| 4 - Solo Exposto | 0 | 2 | 0 | 134 | 3 | 1 | 2 | 0 | 0 | 0 | 0 | 4 | 0 | 0 | 146 | |
| 5 - Cultivo | 0 | 0 | 5 | 3 | 146 | 8 | 2 | 1 | 0 | 0 | 0 | 0 | 2 | 0 | 167 | |
| 6 - Campo Limpo I | 0 | 0 | 2 | 0 | 9 | 82 | 6 | 3 | 0 | 0 | 0 | 2 | 0 | 0 | 104 | |
| 7 - Pastagem | 0 | 0 | 0 | 0 | 6 | 1 | 50 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 57 | |
| 8 - Pomar | 6 | 6 | 0 | 0 | 0 | 1 | 0 | 73 | 0 | 2 | 2 | 4 | 0 | 0 | 94 | |
| 9 - Açude | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 57 | 0 | 0 | 0 | 0 | 1 | 59 | |
| 10 - Açude eutrofizado | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 50 | 0 | 0 | 0 | 0 | 52 | |
| 11 - Sombra | 4 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 71 | 0 | 0 | 0 | 75 | |
| 12 - Estrada | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 37 | 0 | 0 | 37 | |
| 13 - Edificação | 4 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 1 | 45 | 2 | 53 | |
| 14 - Silo | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 4 | 34 | 38 | |
| Total pontos de checagem | 170 | 100 | 58 | 143 | 169 | 98 | 61 | 100 | 57 | 52 | 78 | 51 | 51 | 37 | 1225 | |
| Acurácia do Produtor | 0,9118 | 0,8200 | 0,6897 | 0,9301 | 0,8698 | 0,8469 | 0,7541 | 0,7300 | 1,0000 | 0,9615 | 0,9103 | 0,7255 | 0,8627 | 0,9189 | Exatidão global | 0,8604 |
| Acurácia do Usuário | 0,8659 | 0,7364 | 0,7222 | 0,9178 | 0,8743 | 0,7885 | 0,8772 | 0,7766 | 0,9661 | 0,9615 | 0,9467 | 1,0000 | 0,8491 | 0,8947 | Índice Kappa | 0,8466 |

Tabela 12 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo *Random Forest* para o conjunto 6

| Classe de Uso da Terra | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | Total Classificado | |
|---------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------------------|--------|
| 1 - Mata | 155 | 1 | 1 | 0 | 0 | 1 | 0 | 20 | 0 | 0 | 4 | 0 | 0 | 0 | 182 | |
| 2 - Campo Sujo | 1 | 81 | 7 | 5 | 4 | 3 | 1 | 2 | 0 | 0 | 1 | 3 | 0 | 0 | 108 | |
| 3 - Campo Limpo II | 0 | 10 | 45 | 1 | 0 | 1 | 1 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 60 | |
| 4 - Solo Exposto | 0 | 2 | 0 | 134 | 2 | 1 | 3 | 0 | 0 | 0 | 0 | 4 | 0 | 0 | 146 | |
| 5 - Cultivo | 0 | 0 | 4 | 3 | 150 | 8 | 3 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 169 | |
| 6 - Campo Limpo I | 0 | 0 | 1 | 0 | 6 | 83 | 5 | 4 | 0 | 0 | 0 | 1 | 0 | 0 | 100 | |
| 7 - Pastagem | 0 | 0 | 0 | 0 | 6 | 1 | 48 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 55 | |
| 8 - Pomar | 7 | 6 | 0 | 0 | 0 | 0 | 0 | 72 | 0 | 2 | 2 | 5 | 1 | 0 | 95 | |
| 9 - Açude | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 57 | 0 | 0 | 0 | 0 | 1 | 58 | |
| 10 - Açude eutrofizado | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 50 | 0 | 0 | 0 | 0 | 51 | |
| 11 - Sombra | 4 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 71 | 0 | 0 | 0 | 75 | |
| 12 - Estrada | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 37 | 0 | 0 | 37 | |
| 13 - Edificação | 3 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 46 | 2 | 52 | |
| 14 - Silo | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 3 | 34 | 37 | |
| Total pontos de checagem | 170 | 100 | 58 | 143 | 169 | 98 | 61 | 100 | 57 | 52 | 78 | 51 | 51 | 37 | 1225 | |
| Acurácia do Produtor | 0,9118 | 0,8100 | 0,7759 | 0,9371 | 0,8876 | 0,8469 | 0,7869 | 0,7200 | 1,0000 | 0,9615 | 0,9103 | 0,7255 | 0,9020 | 0,9189 | Exatidão global | 0,8678 |
| Acurácia do Usuário | 0,8516 | 0,7500 | 0,7500 | 0,9178 | 0,8876 | 0,8300 | 0,8727 | 0,7579 | 0,9828 | 0,9804 | 0,9467 | 1,0000 | 0,8846 | 0,9189 | Índice Kappa | 0,8547 |

Tabela 13 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo C5.0 para o conjunto 1

| Classe de Uso da Terra | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | Total Classificado | |
|---------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------------------|--------|
| 1 - Mata | 101 | 8 | 2 | 1 | 2 | 1 | 3 | 21 | 0 | 0 | 4 | 1 | 7 | 2 | 153 | |
| 2 - Campo Sujo | 12 | 72 | 17 | 9 | 6 | 7 | 2 | 7 | 0 | 1 | 0 | 1 | 1 | 0 | 135 | |
| 3 - Campo Limpo II | 14 | 10 | 37 | 1 | 3 | 1 | 1 | 2 | 0 | 0 | 0 | 1 | 0 | 0 | 70 | |
| 4 - Solo Exposto | 0 | 4 | 0 | 128 | 0 | 1 | 1 | 2 | 0 | 0 | 0 | 8 | 3 | 0 | 147 | |
| 5 - Cultivo | 3 | 0 | 1 | 0 | 115 | 5 | 6 | 1 | 0 | 1 | 0 | 0 | 0 | 0 | 132 | |
| 6 - Campo Limpo I | 4 | 0 | 0 | 0 | 13 | 78 | 11 | 5 | 0 | 0 | 0 | 1 | 0 | 0 | 112 | |
| 7 - Pastagem | 1 | 0 | 0 | 0 | 23 | 4 | 36 | 1 | 0 | 0 | 0 | 1 | 0 | 0 | 66 | |
| 8 - Pomar | 24 | 6 | 1 | 0 | 6 | 1 | 1 | 59 | 0 | 4 | 2 | 1 | 1 | 0 | 106 | |
| 9 - Açude | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 56 | 0 | 2 | 0 | 0 | 1 | 60 | |
| 10 - Açude eutrofizado | 2 | 0 | 0 | 3 | 1 | 0 | 0 | 1 | 0 | 46 | 0 | 0 | 3 | 0 | 56 | |
| 11 - Sombra | 7 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 0 | 70 | 0 | 3 | 2 | 84 | |
| 12 - Estrada | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 37 | 0 | 0 | 37 | |
| 13 - Edificação | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 31 | 1 | 34 | |
| 14 - Silo | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 31 | 33 | |
| Total pontos de checagem | 170 | 100 | 58 | 143 | 169 | 98 | 61 | 100 | 57 | 52 | 78 | 51 | 51 | 37 | 1225 | |
| Acurácia do Produtor | 0,5941 | 0,7200 | 0,6379 | 0,8951 | 0,6805 | 0,7959 | 0,5902 | 0,5900 | 0,9825 | 0,8846 | 0,8974 | 0,7255 | 0,6078 | 0,8378 | Exatidão global | 0,7322 |
| Acurácia do Usuário | 0,6601 | 0,5333 | 0,5286 | 0,8707 | 0,8712 | 0,6964 | 0,5455 | 0,5566 | 0,9333 | 0,8214 | 0,8333 | 1,0000 | 0,9118 | 0,9394 | Índice Kappa | 0,7068 |

Tabela 14 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo C5.0 para o conjunto 2

| Classe de Uso da Terra | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | Total Classificado | |
|---------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------------------|--------|
| 1 - Mata | 95 | 10 | 3 | 0 | 2 | 1 | 3 | 23 | 0 | 1 | 6 | 1 | 5 | 1 | 151 | |
| 2 - Campo Sujo | 14 | 71 | 12 | 8 | 4 | 8 | 3 | 6 | 0 | 3 | 0 | 2 | 1 | 0 | 132 | |
| 3 - Campo Limpo II | 17 | 9 | 40 | 1 | 1 | 0 | 2 | 4 | 0 | 0 | 0 | 0 | 2 | 1 | 77 | |
| 4 - Solo Exposto | 0 | 4 | 0 | 127 | 0 | 0 | 0 | 3 | 0 | 0 | 0 | 10 | 2 | 0 | 146 | |
| 5 - Cultivo | 4 | 0 | 1 | 0 | 116 | 6 | 6 | 2 | 0 | 0 | 0 | 0 | 1 | 0 | 136 | |
| 6 - Campo Limpo I | 4 | 0 | 0 | 0 | 12 | 77 | 14 | 4 | 0 | 0 | 0 | 1 | 0 | 0 | 112 | |
| 7 - Pastagem | 2 | 0 | 0 | 0 | 27 | 5 | 33 | 2 | 0 | 0 | 0 | 1 | 0 | 0 | 70 | |
| 8 - Pomar | 25 | 6 | 2 | 0 | 7 | 1 | 0 | 55 | 0 | 4 | 1 | 0 | 0 | 0 | 101 | |
| 9 - Açude | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 56 | 0 | 2 | 0 | 0 | 1 | 60 | |
| 10 - Açude eutrofizado | 0 | 0 | 0 | 6 | 0 | 0 | 0 | 0 | 0 | 44 | 0 | 0 | 6 | 0 | 56 | |
| 11 - Sombra | 8 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 0 | 69 | 0 | 0 | 0 | 79 | |
| 12 - Estrada | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 36 | 0 | 0 | 36 | |
| 13 - Edificação | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 29 | 2 | 32 | |
| 14 - Silo | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 5 | 32 | 37 | |
| Total pontos de checagem | 170 | 100 | 58 | 143 | 169 | 98 | 61 | 100 | 57 | 52 | 78 | 51 | 51 | 37 | 1225 | |
| Acurácia do Produtor | 0,5588 | 0,7100 | 0,6897 | 0,8881 | 0,6864 | 0,7857 | 0,5410 | 0,5500 | 0,9825 | 0,8462 | 0,8846 | 0,7059 | 0,5686 | 0,8649 | Exatidão global | 0,7184 |
| Acurácia do Usuário | 0,6291 | 0,5379 | 0,5195 | 0,8699 | 0,8529 | 0,6875 | 0,4714 | 0,5446 | 0,9333 | 0,7857 | 0,8734 | 1,0000 | 0,9063 | 0,8649 | Índice Kappa | 0,6917 |

Tabela 15 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo C5.0 para o conjunto 3

| Classe de Uso da Terra | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | Total Classificado | |
|---------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------------------|--------|
| 1 - Mata | 155 | 3 | 2 | 0 | 1 | 0 | 0 | 14 | 1 | 0 | 4 | 0 | 2 | 0 | 182 | |
| 2 - Campo Sujo | 1 | 78 | 11 | 9 | 2 | 3 | 2 | 0 | 0 | 0 | 1 | 1 | 0 | 0 | 108 | |
| 3 - Campo Limpo II | 0 | 10 | 39 | 1 | 2 | 0 | 0 | 2 | 0 | 1 | 0 | 0 | 0 | 0 | 55 | |
| 4 - Solo Exposto | 0 | 4 | 0 | 130 | 1 | 2 | 3 | 0 | 0 | 0 | 0 | 6 | 0 | 1 | 147 | |
| 5 - Cultivo | 0 | 0 | 3 | 1 | 131 | 5 | 7 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 147 | |
| 6 - Campo Limpo I | 0 | 2 | 2 | 0 | 16 | 80 | 5 | 6 | 0 | 0 | 0 | 3 | 0 | 0 | 114 | |
| 7 - Pastagem | 0 | 0 | 0 | 0 | 13 | 6 | 44 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 64 | |
| 8 - Pomar | 5 | 3 | 1 | 0 | 0 | 1 | 0 | 76 | 0 | 2 | 2 | 2 | 0 | 0 | 92 | |
| 9 - Açude | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 56 | 0 | 2 | 0 | 0 | 0 | 59 | |
| 10 - Açude eutrofizado | 0 | 0 | 0 | 2 | 2 | 0 | 0 | 1 | 0 | 49 | 0 | 0 | 0 | 0 | 54 | |
| 11 - Sombra | 7 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 69 | 0 | 2 | 1 | 80 | |
| 12 - Estrada | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 38 | 0 | 0 | 38 | |
| 13 - Edificação | 2 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 43 | 3 | 49 | |
| 14 - Silo | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 4 | 32 | 36 | |
| Total pontos de checagem | 170 | 100 | 58 | 143 | 169 | 98 | 61 | 100 | 57 | 52 | 78 | 51 | 51 | 37 | 1225 | |
| Acurácia do Produtor | 0,9118 | 0,7800 | 0,6724 | 0,9091 | 0,7751 | 0,8163 | 0,7213 | 0,7600 | 0,9825 | 0,9423 | 0,8846 | 0,7451 | 0,8431 | 0,8649 | Exatidão global | 0,8327 |
| Acurácia do Usuário | 0,8516 | 0,7222 | 0,7091 | 0,8844 | 0,8912 | 0,7018 | 0,6875 | 0,8261 | 0,9492 | 0,9074 | 0,8625 | 1,0000 | 0,8776 | 0,8889 | Índice Kappa | 0,8163 |

Tabela 16 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo C5.0 para o conjunto 4

| Classe de Uso da Terra | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | Total Classificado | |
|---------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------------------|--------|
| 1 - Mata | 156 | 5 | 3 | 0 | 1 | 0 | 0 | 17 | 1 | 0 | 5 | 0 | 2 | 0 | 190 | |
| 2 - Campo Sujo | 0 | 78 | 8 | 6 | 3 | 4 | 2 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 102 | |
| 3 - Campo Limpo II | 0 | 10 | 41 | 1 | 2 | 0 | 1 | 2 | 0 | 1 | 0 | 0 | 0 | 0 | 58 | |
| 4 - Solo Exposto | 0 | 4 | 0 | 132 | 0 | 1 | 3 | 0 | 0 | 0 | 0 | 6 | 0 | 0 | 146 | |
| 5 - Cultivo | 0 | 0 | 3 | 1 | 136 | 7 | 5 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 152 | |
| 6 - Campo Limpo I | 0 | 0 | 2 | 0 | 13 | 80 | 5 | 5 | 0 | 0 | 0 | 3 | 0 | 0 | 108 | |
| 7 - Pastagem | 0 | 0 | 0 | 0 | 13 | 4 | 45 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 63 | |
| 8 - Pomar | 3 | 3 | 1 | 0 | 0 | 1 | 0 | 73 | 0 | 2 | 2 | 3 | 0 | 0 | 88 | |
| 9 - Açude | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 55 | 1 | 2 | 0 | 0 | 1 | 61 | |
| 10 - Açude eutrofizado | 0 | 0 | 0 | 3 | 1 | 0 | 0 | 1 | 0 | 48 | 0 | 0 | 0 | 0 | 53 | |
| 11 - Sombra | 8 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 69 | 0 | 1 | 1 | 79 | |
| 12 - Estrada | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 37 | 0 | 0 | 37 | |
| 13 - Edificação | 3 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 0 | 43 | 3 | 51 | |
| 14 - Silo | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 5 | 32 | 37 | |
| Total pontos de checagem | 170 | 100 | 58 | 143 | 169 | 98 | 61 | 100 | 57 | 52 | 78 | 51 | 51 | 37 | 1225 | |
| Acurácia do Produtor | 0,9176 | 0,7800 | 0,7069 | 0,9231 | 0,8047 | 0,8163 | 0,7377 | 0,7300 | 0,9649 | 0,9231 | 0,8846 | 0,7255 | 0,8431 | 0,8649 | Exatidão global | 0,8367 |
| Acurácia do Usuário | 0,8211 | 0,7647 | 0,7069 | 0,9041 | 0,8947 | 0,7407 | 0,7143 | 0,8295 | 0,9016 | 0,9057 | 0,8734 | 1,0000 | 0,8431 | 0,8649 | Índice Kappa | 0,8207 |

Tabela 17 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo C5.0 para o conjunto 5

| Classe de Uso da Terra | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | Total Classificado | |
|---------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------------------|--------|
| 1 - Mata | 154 | 3 | 2 | 0 | 0 | 0 | 0 | 16 | 1 | 0 | 2 | 0 | 1 | 0 | 179 | |
| 2 - Campo Sujo | 1 | 77 | 8 | 6 | 3 | 3 | 2 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 101 | |
| 3 - Campo Limpo II | 0 | 10 | 43 | 1 | 1 | 0 | 1 | 1 | 0 | 1 | 0 | 0 | 0 | 0 | 58 | |
| 4 - Solo Exposto | 0 | 5 | 0 | 130 | 1 | 2 | 3 | 0 | 0 | 0 | 0 | 7 | 0 | 0 | 148 | |
| 5 - Cultivo | 0 | 0 | 3 | 2 | 135 | 7 | 4 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 152 | |
| 6 - Campo Limpo I | 0 | 1 | 1 | 0 | 13 | 78 | 6 | 5 | 0 | 0 | 0 | 3 | 0 | 0 | 107 | |
| 7 - Pastagem | 0 | 0 | 0 | 0 | 14 | 6 | 45 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 65 | |
| 8 - Pomar | 5 | 4 | 1 | 0 | 0 | 1 | 0 | 77 | 0 | 2 | 2 | 3 | 0 | 0 | 95 | |
| 9 - Açude | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 55 | 0 | 2 | 0 | 0 | 1 | 59 | |
| 10 - Açude eutrofizado | 0 | 0 | 0 | 4 | 1 | 0 | 0 | 0 | 0 | 49 | 0 | 0 | 0 | 0 | 54 | |
| 11 - Sombra | 7 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 72 | 0 | 2 | 1 | 82 | |
| 12 - Estrada | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 37 | 0 | 0 | 37 | |
| 13 - Edificação | 3 | 0 | 0 | 0 | 1 | 1 | 0 | 0 | 1 | 0 | 0 | 0 | 44 | 3 | 53 | |
| 14 - Silo | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 3 | 32 | 35 | |
| Total pontos de checagem | 170 | 100 | 58 | 143 | 169 | 98 | 61 | 100 | 57 | 52 | 78 | 51 | 51 | 37 | 1225 | |
| Acurácia do Produtor | 0,9059 | 0,7700 | 0,7414 | 0,9091 | 0,7988 | 0,7959 | 0,7377 | 0,7700 | 0,9649 | 0,9423 | 0,9231 | 0,7255 | 0,8627 | 0,8649 | Exatidão global | 0,8392 |
| Acurácia do Usuário | 0,8603 | 0,7624 | 0,7414 | 0,8784 | 0,8882 | 0,7290 | 0,6923 | 0,8105 | 0,9322 | 0,9074 | 0,8780 | 1,0000 | 0,8302 | 0,9143 | Índice Kappa | 0,8235 |

Tabela 18 - Acurácia da classificação do uso e cobertura da terra com a aplicação do algoritmo C5.0 para o conjunto 6

| Classe de Uso da Terra | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | Total Classificado | |
|---------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------------------|--------|
| 1 - Mata | 155 | 9 | 2 | 0 | 1 | 0 | 0 | 17 | 0 | 0 | 3 | 0 | 2 | 0 | 189 | |
| 2 - Campo Sujo | 1 | 74 | 7 | 5 | 3 | 3 | 2 | 1 | 0 | 0 | 1 | 1 | 0 | 0 | 98 | |
| 3 - Campo Limpo II | 0 | 9 | 43 | 1 | 0 | 0 | 1 | 2 | 0 | 1 | 0 | 0 | 0 | 0 | 57 | |
| 4 - Solo Exposto | 0 | 5 | 0 | 132 | 1 | 2 | 3 | 0 | 0 | 0 | 0 | 6 | 0 | 0 | 149 | |
| 5 - Cultivo | 0 | 0 | 3 | 1 | 133 | 7 | 5 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 149 | |
| 6 - Campo Limpo I | 1 | 0 | 2 | 0 | 13 | 78 | 6 | 4 | 0 | 0 | 0 | 3 | 0 | 0 | 107 | |
| 7 - Pastagem | 0 | 0 | 0 | 0 | 17 | 6 | 44 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 68 | |
| 8 - Pomar | 4 | 3 | 1 | 0 | 0 | 1 | 0 | 75 | 0 | 2 | 2 | 2 | 0 | 0 | 90 | |
| 9 - Açude | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 57 | 0 | 2 | 0 | 0 | 1 | 61 | |
| 10 - Açude eutrofizado | 0 | 0 | 0 | 4 | 1 | 0 | 0 | 0 | 0 | 49 | 0 | 0 | 0 | 0 | 54 | |
| 11 - Sombra | 6 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 70 | 0 | 2 | 1 | 79 | |
| 12 - Estrada | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 38 | 0 | 0 | 38 | |
| 13 - Edificação | 3 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 43 | 3 | 50 | |
| 14 - Silo | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 4 | 32 | 36 | |
| Total pontos de checagem | 170 | 100 | 58 | 143 | 169 | 98 | 61 | 100 | 57 | 52 | 78 | 51 | 51 | 37 | 1225 | |
| Acurácia do Produtor | 0,9118 | 0,7400 | 0,7414 | 0,9231 | 0,7870 | 0,7959 | 0,7213 | 0,7500 | 1,0000 | 0,9423 | 0,8974 | 0,7451 | 0,8431 | 0,8649 | Exatidão global | 0,8351 |
| Acurácia do Usuário | 0,8201 | 0,7551 | 0,7544 | 0,8859 | 0,8926 | 0,7290 | 0,6471 | 0,8333 | 0,9344 | 0,9074 | 0,8861 | 1,0000 | 0,8600 | 0,8889 | Índice Kappa | 0,8190 |