

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

UMA ABORDAGEM DE CLASSIFICAÇÃO DA COBERTURA DA TERRA EM  
IMAGENS OBTIDAS POR VEÍCULO AÉREO NÃO TRIPULADO

Luis Fernando Chimelo Ruiz

Orientador: Laurindo Antonio Guasselli

Coorientador: Alexandre ten Caten

Porto Alegre, 29 de janeiro de 2015

LUIS FERNANDO CHIMELO RUIZ

UMA ABORDAGEM DE CLASSIFICAÇÃO DA COBERTURA DA TERRA EM  
IMAGENS OBTIDAS POR VEÍCULO AÉREO NÃO TRIPULADO

Dissertação de Mestrado em Sensoriamento Remoto  
Para obtenção do título de Mestre em Sensoriamento Remoto  
Universidade Federal do Rio Grande do Sul  
Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia

Orientador: Dr. Laurindo Antonio Guasselli (UFRGS)

Coorientador: Dr. Alexandre ten Caten (UFSC)

Porto Alegre

2015

**Aprovado pela Banca Examinadora em  
cumprimento ao requisito exigido para  
obtenção do  
Título de Mestre em Sensoriamento Remoto.**

---

Dr. Elódio Sebem (UFSM)

---

Dr. Guilherme Garcia de Oliveira (UNIVATES)

---

Dr. Daniel Capella Zanotta (IFRS)

---

Dr. Laurindo Antonio Guasselli (UFRGS)  
Orientador

---

Dr. Alexandre ten Caten (UFSC)  
Coorientador

Luis Fernando Chimelo Ruiz

Porto Alegre, 29 de janeiro de 2015

## **AGRADECIMENTOS**

À CAPES pela bolsa de estudo em nível de pós-graduação e pelo financiamento do Veículo Aéreo Não Tripulado, Echar 20A.

À Universidade Federal do Rio Grande do Sul pela estrutura disponibilizada para a realização deste trabalho.

Aos funcionários do Programa em Pós-Graduação em Sensoriamento Remoto, em especial José Luis Rockenbach pelas ajudas no campo.

Ao meu orientador Laurindo Antonio Guasselli pelos conhecimentos transmitidos, pelas críticas construtivas e pela ética profissional.

Ao meu coorientador Alexandre ten Caten que tem me acompanhado desde minha formação de nível técnico, incentivando-me a carreira acadêmica.

Ao pessoal do Laboratório de Geoprocessamento em Análise Ambiental pelas conversas, pelos cafés, pelos churrascos e por terem me recebido muito bem.

Aos Sensorientos pelas conversas animadas, pelos problemas solucionados e pelos problemas criados.

Aos meus amigos Raquel, Élton, Joziane, Cristofer, Diniz, Bruno e Henrique pela torcida e pelo apoio.

Ao Vagner Mengue pelo suporte nos voos e pelo aprendizado transmitido.

Aos meus pais Antonio e Irene que sempre acreditaram em mim e fizeram tudo que estava ao seu alcance para me ajudar.

A Tatiana Teixeira pela compreensão nas horas que faltei e pelo incentivo nos momentos difíceis.

## RESUMO

Câmaras não métricas acopladas a Veículos Aéreos Não Tripulados (VANT) possibilitam coleta de imagens com alta resolução espacial e temporal. Além disso, o custo de operação e manutenção desses equipamentos são reduzidos. A classificação da cobertura da terra por meio dessas imagens são dificultadas devido à alta variabilidade espectral dos alvos e ao grande volume de dados gerados. Esses contratempos são contornados utilizando Análise de Imagens Baseada em Objetos (*Object-Based Image Analysis* – OBIA) e algoritmos de mineração de dados. Um algoritmo empregado na OBIA são as Árvores de Decisão (AD). Essa técnica possibilita tanto a seleção de atributos mais informativos quanto a classificação das regiões. Novas técnicas de AD foram desenvolvidas e, nessas inovações, foram inseridas funções para selecionar atributos e para melhorar a classificação. Um exemplo é o algoritmo C5.0, que possui uma função de redução de dados e uma de reforço. Nesse contexto, este trabalho tem como objetivo (i) avaliar o método de segmentação por crescimento de regiões em imagens com altíssima resolução espacial, (ii) determinar os atributos preditivos mais importantes na discriminação das classes e (iii) avaliar as classificações das regiões em relação aos parâmetros de seleção dos atributos (*winnow*) e de reforço (*trial*), que estão contidos no algoritmo C5.0. A segmentação da imagem foi efetuada no programa Spring, já as regiões geradas na segmentação foram classificadas pelo modelo de AD C5.0, que está disponível no programa R. Como resultado foi identificado que a segmentação crescimento de regiões possibilitou uma alta correspondência com regiões geradas pelo especialista, resultando em valores de *Reference Bounded Segments Booster* (RBSB) próximos a 0. Os atributos mais importantes na construção dos modelos por AD foram a razão entre a banda do verde com a azul ( $r_{v_a}$ ) e o Modelo Digital de Elevação (MDE). Para o parâmetro de reforço (*trial*), não foi identificada melhora na acurácia da classificação ao aumentar seu valor. Já o parâmetro *winnow* possibilitou uma redução no número de atributos preditivos, sem perdas estatisticamente significativas na acurácia da classificação. A função de reforço (*trial*) não melhorou a classificação da cobertura da terra. Também não foram constatadas diferenças estatisticamente significativas quando *winnow* selecionado como verdadeiro, mas se encontrou o benefício desse último parâmetro reduzindo a dimensionalidade dos dados. Nesse sentido, este trabalho contribuiu para a classificação da cobertura da terra em imagens coletadas por VANT, uma vez que se desenvolveu algoritmos para automatizar os processos da OBIA e para avaliar a classificação das regiões em relação às funções de reforço (*winnow*) e de seleção do atributo (*winnow*) do classificador por árvore de decisão C5.0.

Palavras-chave: análise de imagens baseada em objetos, árvore de decisão, imagens de alta resolução espacial.

## ABSTRACT

Non-metric cameras attached to Unmanned Aerial Vehicles (UAV) enable collection of images with high spatial and temporal resolution. In addition, the cost of operation and maintenance of equipment are reduced. The land cover classification through these images are hampered due to high spectral variability of the targets and the large volume of data generated. These setbacks are contoured using Image Analysis Based on Objects (OBIA) and data mining algorithms. An algorithm used in OBIA are Decision Trees (AD). This technique allows the selection of the most informative attributes as the classification of regions. New AD techniques have been developed and these innovations, were functions inserted to select attributes and to improve classification. One example is a C5.0 algorithm, which has a data reduction function and of boosting. In this context, this paper aims to (i) evaluate the segmentation method for growing regions in images with high spatial resolution, (ii) determine the most important predictive attributes in the discrimination of classes and (iii) evaluate the classifications of regions regarding the attributes selection parameters (winnow) and boosting (trial), which are contained in the C5.0 algorithm. The image segmentation was performed in Spring program, since the regions generated in segmentation were classified by model C5.0, which is available in the program R. As a result it was identified that the segmentation by region growing provided a high correlation with regions generated by the expert, resulting in Reference Bounded Segments Booster values (RBSB) near 0. The most important features in the construction of models of decision tree are the ratio between the band of green with the blue ( $r_{v_a}$ ) and the Digital Elevation Model (DEM). Was not identified improvement in classification accuracy when was increased value of trial parameter. Already winnow parameter enabled a reduction in the number of predictive attributes, with no statistically significant losses in the accuracy of the classification. The boosting function (trial) did not improve the classification of land cover. Also were not found statistically significant differences when winnow selected as true, but was found the benefit of the latter parameter to reducing the dimensionality of the data. Thus, this work contributed to the land cover classification in images collected by UAV, once that were developed algorithms to automate the processes of integration OBIA and decision tree (C5.0).

Keywords: object-based image analysis, decision tree, high resolution spatial images.

## SUMÁRIO

1 INTRODUÇÃO.....	13
1.1 Objetivo geral.....	15
1.2 Objetivos específicos.....	15
2 REFERENCIAL TEÓRICO.....	16
2.1 Veículos Aéreos Não Tripulados (VANT) e sensores.....	16
2.2 Processamento das imagens e aplicações.....	21
2.3 Análise de imagens baseada em objetos.....	24
2.3.1 Análise baseada em objetos versus baseada em pixel.....	24
2.3.2 Métodos de segmentação.....	25
2.4 Classificadores.....	30
2.4.1 Paramétricos e não paramétricos.....	30
2.4.2 Árvore de decisão.....	33
MATERIAIS E MÉTODOS.....	39
3.1 Aquisição das imagens.....	39
3.2 Processamento das imagens.....	41
3.3 Segmentação.....	42
3.4 Avaliação das segmentações.....	43
3.5 Extração dos atributos preditores.....	44
3.5.1 Atributos espectrais.....	44
3.5.2 Atributos texturais.....	45
3.5.3 Modelo Digital de Elevação.....	50
3.5.4 Atributos geométricos.....	50
3.6 Seleção das regiões de treinamento.....	52
3.7 Construção dos modelos por AD.....	55
3.8 Classificação das segmentações.....	57
3.9 Validação das classificações.....	57
4 RESULTADOS E DISCUSSÕES.....	61
4.1 Avaliação das segmentações.....	62
4.2 Modelos por Árvore de Decisão (AD).....	66
4.3 Classificações.....	73
5 CONCLUSÃO.....	86
REFERÊNCIAS.....	88
APÊNDICES.....	96

## LISTA DE FIGURAS

Figura 1 - Classificação dos VANT.....	16
Figura 2 - Regiões formadas pela segmentação, a) subsegmentação e b) sobresegmentação.....	26
Figura 3 - Representação da classificação paramétrica, a) FDP das classes e b) as fronteiras de decisão das classes, geradas pela FDP.....	29
Figura 4 - Árvore de decisão ilustrativa.....	32
Figura 5 - Fronteiras de decisão da classificação por AD.....	33
Figura 6 - Fluxograma das etapas executadas.....	36
Figura 7 - Aeronave Echar 20A e equipamentos auxiliares.....	37
Figura 8 - Método RBSB.....	41
Figura 9 - Ângulos de análises.....	43
Figura 10 - Imagem com seis níveis de cinza.....	44
Figura 11 - Ortoimagem da área de estudo.....	60
Figura 12 - a) ortoimagem representada na escala 1:1600 e as regiões geradas pelo especialista, b) segmentação com limiar de similaridade 1, c) segmentação com limiar de similaridade 15 e d) segmentação com limiar de similaridade 50.....	63
Figura 13 - a) ortoimagem representada na escala 1:800 e as regiões geradas pelo especialista, b) segmentação com limiar de similaridade 1, c) segmentação com limiar de similaridade 15 e d) segmentação com limiar de similaridade 50.....	64
Figura 14 - Taxa de uso dos atributos na construção dos modelos para o parâmetro winnow igual a falso.....	67
Figura 15 - Importância dos atributos na construção dos modelos (winnow = true)..	69
Figura 16 - Taxa de uso dos atributos na construção dos modelos para o parâmetro winnow igual a verdadeiro.....	70
Figura 17 - Índice kappa obtidos nas classificações a) valores do kappa para winnow igual a falso e b) valores do kappa para winnow igual a verdadeiro.....	73
Figura 18 - Diferença dos índices kappa para os mesmos valores limiares e trial....	74
Figura 19 - Teste K entre os modelos gerados com winnow igual a falso e igual a verdadeiro.....	75
Figura 20 - Valores médios e o desvio padrão dos dados de treinamento da segmentação com limiar igual a 15.....	81
Figura 21 - Ortoimagem e as respectivas classificações.....	85
Figura 22 - Classificação da ortoimagem do modelo treinado com amostras do limiar igual 15, trial a zero e winnow igual a falso.....	86

## LISTA DE TABELAS

Tabela 1 - Resumo dos VANT comercializados.....	17
Tabela 2 - Matriz de frequência dos pares de pixels da Figura 10, para uma distância de um pixel e ângulo de 90°.....	45
Tabela 3 - Matriz de coocorrência calculada a partir da matriz de frequências.....	45
Tabela 4 - Classes de cobertura da terra e suas respectivas números de amostras.....	51
Tabela 5 - Amostras de validação distribuída entre as classes.....	56
Tabela 6 - Tempo de processamento e número total de regiões.....	61
Tabela 7 - Área média e RBSB.....	62
Tabela 8 - Taxas de acerto dos modelos em relação aos dados de treinamento e número de folhas.....	66
Tabela 9 - Matriz de confusão do limiar igual a 15, trial igual a 0 e winnow igual a falso.....	79

## LISTA DE QUADROS

Quadro 1 - Código de construção dos modelos por C5.0.....	55
Quadro 2 - Regra de classificação para a classe construção.....	80

## APÊNDICES

APÊNDICE A – Código para avaliação nas imagens segmentadas.....	97
APÊNDICE B – Rotina para calcular valores médios dos atributos para as regiões.	98
APÊNDICE C – Algoritmo para calcular os atributos geométricos das regiões.....	99
APÊNDICE D – Código para classificar as segmentações.....	100
APÊNDICE E – Algoritmo de validação das classificações.....	101
APÊNDICE F – Árvore de decisão.....	102

## LISTA DE ABREVIATURAS E SIGLAS

AC - Água/cinza  
ACE - Adaptive Cosine Estimator  
ACP - Análise por Componentes Principais  
AD - Árvore de Decisão  
AESA - European Aviation Safety Agency  
AG - Água  
ANAC - Agência Nacional de Aviação Civil  
AP - Acurácia do Produtor  
APR - Aeronave Pilotada Remotamente  
AU - Acurácia do Usuário  
BA - Banhado  
CA - Campo  
CAPES – Centro de Aperfeiçoamento de Pesquisa e Extensão Superior  
CART - Classification And Regression Tree  
CAVE - Certificado de Autorização de Voo Experimental  
CO - Construção  
CPU - Central Processing Unit  
CTA - Comando-Geral de Tecnologia Aeroespacial  
EUA - Estados Unidos da América  
FAA - Federal Aviation Administration – FAA  
FDP - Função de Densidade Probabilística  
GDAL - Geospatial Data Abstraction Library  
GLCM - Grey Level Cooccurrence Matriz  
GNDVI - Green Normalized Difference Vegetation Index  
GNSS - Global Navigation Satellite System  
GPU - Graphics Processing Unit  
HALE - High Altitude and Long Endurance  
ICAO - International Civil Aviation Organization  
IMU - Inertial Measurement Unit  
INPE - Instituto Nacional de Pesquisas Espaciais  
IS - Instrução Suplementar  
IVP - Infra Vermelho Próximo  
LALE - Low Altitude and Long Endurance  
LASE - Low Altitude and Short-Endurance  
LIDAR - Light Detection And Ranging  
MA - Macrófita  
MALE - Medium Altitude and Long Endurance  
MASO - Momento Angular de Segunda Ordem  
MAV - Micro Air Vehicle  
MDE - Modelo Digital de Elevação  
MILC - Mirrorless interchangeable-Lens Camera  
MLME - Modelo Linear de Mistura Espectral  
MN - Mata nativa  
MVS - Máquina Vetor de Suporte  
MVS - Máquina Vetor de Suporte  
NASA - National Aeronautics and Space Administration  
NAV - Nano Air Vehicle  
ND - Níveis Digitais

OBIA - Object-Based Image Analysis  
OS - Operating System  
PA - Pastagem  
RBAC - Regulamento Brasileiro da Aviação Civil  
RBSB - Reference Bounded Segments Booster  
RE - Resteva  
RNA - Redes Neurais Artificiais  
RPAS - Remotely-Piloted Aerial System  
SAM - Spectral Angle Mapper  
SANT - Sistema de Aeronave Não Tripulado  
SE - Solo exposto  
SIFT - Scale Invariant Feature Transform  
SisVANT - Sistema de Veículo Aéreo Não Tripulado  
SO - Sombra  
SU - Solo úmido  
SV - Silvicultura  
TIN - Triangular Irregular Network  
UASSG - Unmanned Aerial Systems Study Group  
UFRGS - Universidade Federal do Rio Grande do Sul  
UTM - Universo Transverso de Mercator  
VANT - Veículo Aéreo Não Tripulado  
VTOL - Vertical Take-Off and Landing

## 1 INTRODUÇÃO

Entender os padrões e a dinâmica da cobertura da terra é essencial para compreender as atividades dos seres humanos no ambiente. Tais atividades, por sua vez, causam alterações locais e globais e o entendimento dessas alterações, ainda é limitado (Jia et al., 2014). Essa limitação pode estar relacionada a estudos que necessitam de dados com alta resolução espacial (Flener et al., 2013) e temporal (Saarinen et al., 2013).

Sensores orbitais possuem uma repetibilidade de coleta de imagens de forma síncrona. Em alguns casos é possível pré-programar o sistema do sensor para coletar imagens com outro ângulo de visada. Para estudos relacionados ao monitoramento ambiental e desastres naturais, essa repetibilidade de imagens pode não ser a mais adequada, como por exemplo, para o monitoramento de queimadas, inundações e deslizamento de massa.

Aerolevantamentos fotogramétricos podem ser uma opção nesses casos, no entanto, os custos desses levantamentos são altos, devido aos valores dos equipamentos utilizados, como também, pela necessidade de um piloto e de uma equipe a bordo, para apoiar o funcionamento do equipamento e da aeronave (Haubeck e Prinz, 2013).

Uma alternativa seria o uso de câmaras de baixo custo acoplada a um Veículo Aéreo Não Tripulado (VANT). Essa tecnologia possui baixo de custo de operação e manutenção, além de proporcionar a obtenção de dados em locais inacessíveis (Everaerts, 2008). Como na maioria dos levantamentos com VANT os voos são em baixa altitude, o tempo nublado não é um problema, mas há limitações para a velocidade do vento (Torres-Sánchez, 2014). A flexibilidade da programação dos voos, juntamente, com os voos em baixa altitude proporciona a obtenção de dados em altíssima resolução temporal e espacial (Turner et al., 2012).

Ao mesmo tempo em que essa tecnologia de obtenção de dados resolve alguns problemas, novos obstáculos são encontrados. A alta variabilidade espectral dos objetos e o grande volume de dados gerados trazem dificuldades para a classificação dessas imagens. Esse volume de dados é o resultado da alta resolução espacial do mosaico de imagens, dos atributos espectrais e texturais possíveis de serem extraídos das imagens, como também, dos atributos

geométricos e contextuais gerados das regiões ( Lechner et al., 2012).

Análise de Imagens Baseada em Objetos (*Object-Based Image Analysis – OBIA*) e algoritmos de mineração de dados estão sendo utilizados na classificação da cobertura da terra em imagens de alta resolução, com intuito de diminuir o número de objetos de análise e a dimensionalidade do conjunto de dados (Laliberte et al., 2007).

Na OBIA há duas etapas principais, a primeira etapa é a segmentação da imagem, que tem como objetivo dividir uma imagem em regiões espacialmente contínuas, disjuntivas e homogêneas (Pekkarinen, 2002). A segunda etapa preocupa-se com a classificação dessas regiões.

Métodos comuns utilizados na segmentação de imagens são as segmentações multirresolução. Esses métodos consideram mais de um parâmetro para formar as regiões homogêneas das imagens. Diferentes valores para esses parâmetros resultam em distintas segmentações (Neubert et al., 2006).

Na etapa de classificação devido ao volume de dados gerados estão sendo utilizadas técnicas que possibilitam a seleção de atributos mais informativos e posteriormente, por meio desses atributos, as regiões são classificadas. Algoritmos de mineração de dados possibilitam tanto a seleção desses atributos quanto a classificação dessas regiões. Entre as técnicas mais utilizadas estão a Árvore de Decisão (AD) (Laliberte et al., 2011a; Hamedianfar et al., 2014), Máquina Vetor de Suporte (MVS) (Chutia et al., 2014), e também, as abordagens híbridas (Heumann et al., 2011).

As AD apresentam vantagens na realização do processo de seleção dos atributos e na classificação das regiões, como: a facilidade de interpretação dos seus resultados, o baixo tempo de processamento na construção do modelo e por não demandar que os atributos apresentem comportamento semelhante a distribuição normal (Friedl e Brodley, 1997).

Os modelos por AD comumente empregados na OBIA não possuem funções específicas para a seleção de atributos mais informativos, como é o caso da regressão por árvore (*Classification And Regression Tree - CART*) (Laliberte et al., 2012; Hellesen e Matikainen, 2013) e do J48 (Hamedianfar et al., 2014). A seleção dos atributos por meio desses modelos se dá a partir da avaliação da AD resultante e da taxa de uso dos atributos na construção dessa AD (Fernandes et al., 2014). Um novo algoritmo que possui rotinas de seleção de atributos é o modelo por AD C5.0,

esse modelo foi mantido como comercial até 2011, desde então, seu código foi disponibilizado para a comunidade científica (Kuhn e Johnson, 2013).

Além dessa inovação, também foi disponibilizado nesse algoritmo uma função de reforço, que tem como objetivo melhorar a taxa de acerto do modelo. O método de seleção de atributos é controlado pelo parâmetro *winnow* e o método de reforço pelo *trial*. Diferentes valores para esses parâmetros geram distintos modelos. Devido a recente disponibilidade desse modelo são necessárias investigações para avaliar se esses novos métodos produzem resultados satisfatórios.

## 1.1 Objetivo geral

Avaliar a classificação da cobertura da terra a partir de imagens coletadas por VANT, integrando OBIA e árvore de decisão.

## 1.2 Objetivos específicos

- Desenvolver algoritmos para automatizar a integração da OBIA e o classificador C5.0;
- Avaliar o método de segmentação multirresolução disponível no programa Spring, com o método crescimento de regiões em imagens com altíssima resolução espacial;
- Determinar os atributos preditivos mais importantes na discriminação das classes;
- Avaliar as classificações das regiões em relação aos parâmetros de seleção de atributos (*winnow*) e de reforço (*trial*), que estão contidos no algoritmo C5.0.

## 2 REFERENCIAL TEÓRICO

### 2.1 Veículos Aéreos Não Tripulados (VANT) e sensores

A comunidade científica demonstrou interesse pelos VANT após ao período da Guerra Fria. Os programas elaborados pela *National Aeronautics and Space Administration* (NASA) dos Estados Unidos da América, entre as décadas de 70 a 90, foram o marco inicial do desenvolvimento de VANT com objetivos científicos para comunidade civil. Como essa tecnologia era desenvolvida para fins militares, os VANT eram de grande porte e de alto custo. Desse modo, os projetos de pesquisa preocuparam-se com a miniaturização dos sensores e das plataformas (Watts et al., 2012; Colomina e Molina, 2014).

No Brasil, o surgimento dos VANT iniciou pelo Comando-Geral de Tecnologia Aeroespacial (CTA), no ano de 1984, com o projeto denominado Acauã. Os objetivos desse projeto eram em aplicações militares e civis. Dentre as aplicações civis, estava o interesse de estudos ambientais e a fiscalização de dutos de gás e óleo (Longhitano, 2010).

Os VANT representam uma evolução tecnológica nas áreas da automação e da robótica. Essa tecnologia possui sistema de telemetria, Sistema Global de Navegação por Satélite (*Global Navigation Satellite System* - GNSS) e Unidade de Medida Inercial (IMU - *Inertial Measurement Unit*). A telemetria é utilizada para realizar a comunicação entre a aeronave e a estação em solo, já o IMU é composto por medidores de força da gravidade, orientação e velocidade da embarcação (Han et al., 2011). Combinando esses dispositivos eletrônicos, essas aeronaves realizam voos autônomos, controlado remotamente e sem piloto a bordo.

A partir dessas facilidades, surgiram as várias denominações para essas aeronaves, entre as mais utilizadas estão: Aeronave Pilotada Remotamente (APR), Sistema de Aeronave Não Tripulado (SANT), Sistema de Veículo Aéreo Não Tripulado (SisVANT), ou ainda são citados como Drones (Watts et al., 2012).

A Organização da Aviação Civil Internacional (*International Civil Aviation Organization* – ICAO) reconhece, para fins da regulamentação dessas aeronaves, a nomenclatura Sistema Aéreo Pilotado Remotamente (*Remotely-Piloted Aerial*

System – RPAS) (ICAO, 2011).

A classificação dessas plataformas segue descrições militares e são diferenciadas pelo tamanho, autonomia de voo e capacidade de carga. A nomenclatura utilizada na comunidade científica é a seguinte:

**Micro Air Vehicle (MAV) ou Nano Air Vehicle (NAV):** São assim chamados devido ao seu tamanho, essas plataformas operam em baixas altitudes, menos que 330 metros e com tempo de voo de 5 a 30 minutos.

**Vertical Take-Off and Landing (VTOL):** A decolagem e aterrissagem dessas aeronaves são na vertical, não necessitando de pista. São utilizadas em baixas altitudes, com alta potência para pairar sobre ar e, devido a isso, o tempo de voo é limitado.

**Low Altitude and Short-Endurance (LASE):** Pequenas aeronaves que também não necessitam de pista para lançamento e aterrissagem, são tecnologias otimizadas, com objetivo de facilitar sua operação. Essas aeronaves pesam de 2 a 5 kg e possuem envergaduras menores que 3 m. Com essa configuração essas aeronaves possibilitam o lançamento com a mão ou com catapulta. No geral, esses sistemas possuem um tempo de comunicação que varia de 1 a 2 horas, com distância limitada a poucos km da estação em solo.

**LASE Close:** São aeronaves pequenas que necessitam de pista, outra diferença da categoria anterior é em relação à altitude de voo que pode chegar a 1500 m, permanecendo por várias horas no ar.

**Low Altitude and Long Endurance (LALE):** Essas aeronaves podem transportar cargas com vários kg, em altitudes de milhares de metros e com tempos superiores a 30 h.

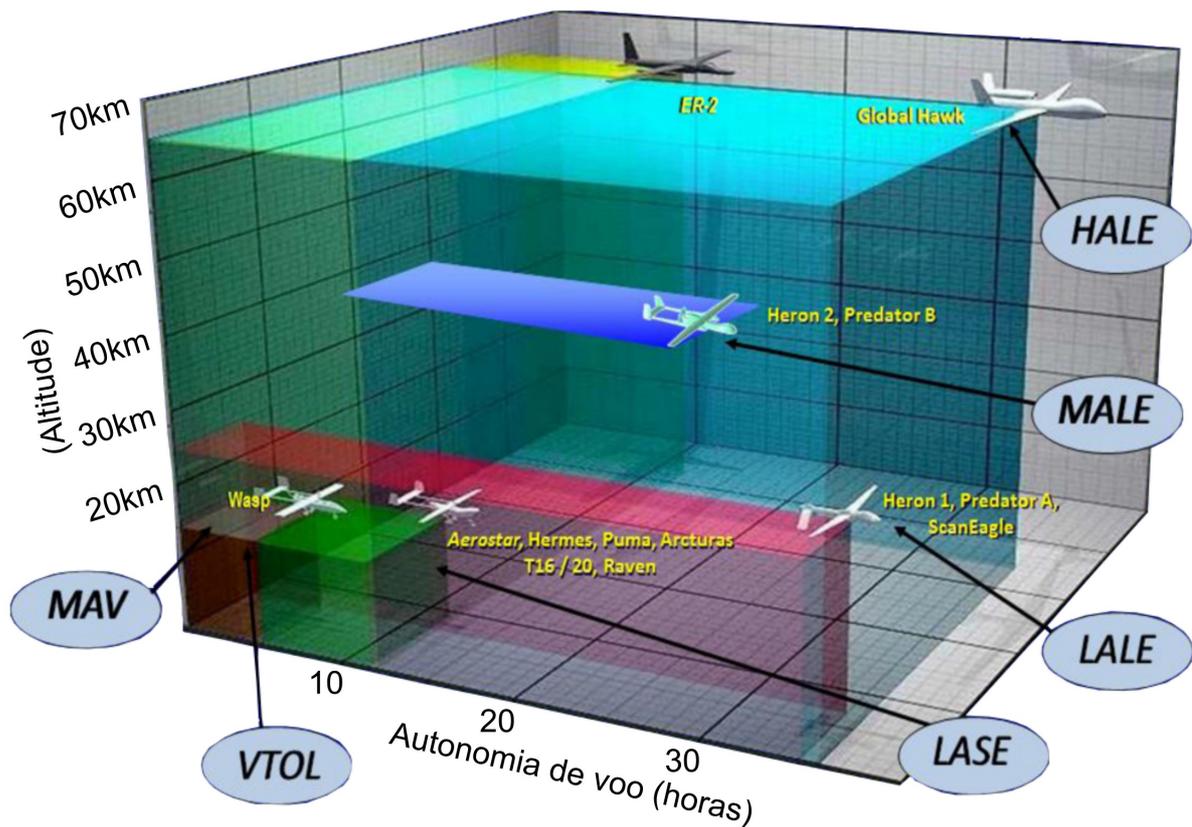
**Medium Altitude and Long Endurance (MALE):** São aeronaves superiores às utilizadas em baixa altitude, que operam em altitudes de até 9000 m, também conseguem se distanciar centenas de km da estação em solo, com tempo de voo que duram muitas horas.

**High Altitude and Long Endurance (HALE):** Os VANT dessa categoria são os maiores e mais complexos, contemplando aeronaves maiores que as existentes na aviação tripulada. Essas aeronaves podem voar a uma altitude de 20000 m ou mais, em voos que se estendem por milhares de km. Algumas aeronaves dessa categoria têm duração de voo mais de 30 h.

Essa classificação foi descrita por Polski (2004) e no trabalho de Watts et al.

(2012). A Figura 1 exemplifica cada categoria, demonstrando o intervalo de altitude e a autonomia de voo para as categorias. Também traz os nomes de algumas aeronaves que se enquadram na classificação.

Figura 1 - Classificação dos VANT.



Fonte: Polski (2004) (tradução própria).

Na área da fotogrametria e no sensoriamento remoto, os VANT comumente utilizados se enquadram na classificação MAV, VTOL ou LASE. Essas categorias são requeridas nessa área do conhecimento devido ao baixo custo do equipamento e pela facilidade de operação. Colomina e Molina (2014) apresentam em seu trabalho um resumo das aeronaves disponíveis no cenário internacional, também as diferenciam em: asas fixas, helicópteros e multirrotores. A Tabela 1 apresenta um resumo dos VANT disponíveis no exterior.

Tabela 1 - Resumo dos VANT comercializados no exterior

Nomes	Fabricantes	Pesos (kg)	Autonomia (h)	carga (c) ou peso da carga (pc)
Asas fixa				
SwingletCAM	SenseFly	0,5	0,5	(c) 16 mp RGB câmara
GeoScan101	GeoScan	2	1	(c) 24.3 mp RGB câmara
UX5	Trimble	2,5	0,83	(c) 16.1 mp MILC RGB câmara
Pteryx	FotoMapy	5	2	(pc) 1 kg baterias
Sirius I	MAVinci	3	0,91	(c) 16 mp RGB câmara
Kahu	Skycam	4	2	(c) 16 mp MILC RGB câmaras
Helicópteros				
Geocopter	IGI	90	2	(pc) 30 kg
Scout B1-100	Aeroscout	75	1,5	(pc) 30 kg
R-MAX, type II	Yamaha	100	1	(pc) 28 kg
Multirrotores				
md4-1000	Microdrones	3	1,42	(pc) 1.2 kg
HT-8-2000	Height-Tech	2,4	0,28	(pc) 2 kg
Aibot x6	Aibotix	2,4	30	(pc) 2.5 kg
Falcon 8	Ascending technologies	1,45	0,33	(pc) 0.75 kg
HexaKopter	MikroKopter	1,2	0,6	(pc) 1 kg

A discussão mundial a respeito da regulamentação do uso dessas aeronaves iniciou em 2007, quando foi criado pela ICAO o Grupo de Estudo em Sistemas Aéreos Não Tripulados (*Unmanned Aerial Systems Study Group – UASSG*), com intuito de ser o coordenador dos trabalhos relacionados a VANT. O primeiro documento oficial da ICAO sobre esse assunto foi disponibilizado em 2011, com a Circular 328 (ICAO, 2011), que tem como objetivos:

(a) Informar a perspectiva da ICAO sobre a integração dos VANT no espaço aéreo;

(b) Considerar as fundamentais diferenças entre a aviação tripulada e o que essa integração vai envolver;

(c) Incentivar os países a ajudarem com o desenvolvimento da política da ICAO em relação aos VANT, fornecendo informações sobre as suas próprias experiências associadas a essas aeronaves.

Já em agosto de 2009, a Agência Europeia para a Segurança da Aviação (*European Aviation Safety Agency - AESA*) elaborou uma declaração política tratando o tema da aeronavegabilidade e certificação de Sistemas de Aeronaves Não Tripuladas, retratando as políticas que estabelecem princípios gerais para a certificação de SisVANT (Colomina e Molina, 2014).

Nos Estados Unidos da América (EUA), a Administração Federal de Aviação (*Federal Aviation Administration – FAA*) autorizou o primeiro voo dessas aeronaves no espaço aéreo nacional em 1990. Atualmente, o uso civil dos VANT no espaço aéreo só pode ser realizado na categoria experimental. Regulamentos de certificação experimental apenas possibilitam operações de pesquisa e desenvolvimento, como demonstrações de voos e de vendas (FAA, 2015).

No Brasil, a regulamentação para o uso dessa tecnologia foi realizada em 2012 pela Agência Nacional de Aviação Civil (ANAC), a partir da Instrução Suplementar (IS) 21-002. A IS objetiva orientar a emissão de Certificado de Autorização de Voo Experimental (CAVE) com base no Regulamento Brasileiro da Aviação Civil nº 21 – (RBAC) para Veículos Aéreos Não Tripulados (VANT). O CAVE é o certificado de aeronavegabilidade para VANT experimentais, com propósitos de pesquisa, desenvolvimento e treinamento de tripulações (ANAC, 2012).

Atualmente, há oferta de inúmeros VANT no mercado, com distintos tamanhos e autonomia de voo, e sensores que abrangem diferentes faixas do espectro eletromagnético (Yastikli et al., 2013). Entre os sensores mais utilizados nesse tipo de plataforma estão as câmaras fotográficas de baixo custo (Haubeck e Prinz, 2013). Como essas câmaras são de baixo custo, as lentes não possuem parâmetros de calibração, esses parâmetros são utilizados na etapa de alinhamento das imagens. Uma forma de obtê-los é a partir de técnicas de computação visual, utilizando como referência imagens capturadas sobre locais com medidas conhecidas (Fraser et al., 1992).

Além disso, câmaras de baixo custo também estão sendo modificadas para capturar imagens em outros comprimentos de onda. Hunt et al. (2010) inseriram um filtro no comprimento de onda do infravermelho próximo em uma câmara Fuji FinePix S3 Pro, para analisar o Índice de Vegetação por Diferença Normalizada do Verde (*Green Normalized Difference Vegetation Index - GNDVI*) com índice de área foliar, os autores encontraram um  $R^2$  de 0,85.

Sensores multiespectrais acoplados a VANT também estão sendo utilizados

na agricultura e na classificação da cobertura da terra. Berni et al. (2009) utilizaram duas câmaras para avaliar produtos quantitativos de campos agrícolas. A primeira câmara capturou imagens de seis comprimentos de onda entre 400 a 800 nm, já a segunda coletou imagens na banda do termal. Essas imagens foram transformadas em reflectância utilizando dados de campo. Com isso foram gerados o índice de área foliar, o teor de clorofila, a detecção de estresse hídrico e a temperatura das copas. Esses produtos possibilitaram resultados comparáveis a sensores tradicionais.

Laliberte et al. (2011b), utilizando uma câmara com seis filtros em diferentes faixas do espectro eletromagnético, conseguiram diferenciar, vegetações em nível de espécie com uma acurácia global de 87%. Analisando as amostras de reflectância coletadas a campo com as imagens corrigidas, a autora encontrou um  $R^2$  de 0,92.

## 2.2 Processamento das imagens e aplicações

As imagens obtidas a partir de câmaras não métricas, aliadas às técnicas de computação visual e de fotogrametria digital possibilitam processos automáticos para a aquisição de mosaicos de imagens ortorretificadas e nuvem de pontos com valores altimétricos (Turner et al., 2012).

O primeiro processo para gerar esses produtos a partir dessas imagens, é por meio do alinhamento das imagens correspondentes. O processo inicia procurando características e descritores nas imagens, e para facilitar a busca, são utilizadas as coordenadas obtidas pelo sistema GNSS. Com as características e descritores comuns encontrados para imagens correspondentes, são calculados os ângulos de rotação e translação para alinhar as imagens. Um algoritmo muito utilizado para encontrar as características e os descritores é o *Scale Invariant Feature Transform* (SIFT) (Moranduzzo e Melgani, 2013). Posteriormente, para realizar o ajuste do bloco de imagens são utilizadas técnicas da fototriangulação. Mas nesse caso, o ajuste por feixes perspectivos é realizado em um sistema arbitrário, não sendo necessário especificar *a priori* pontos de controle com coordenadas tridimensionais, porque a geometria da cena, orientações e posições da câmara são resolvidas

automaticamente, utilizando um procedimento iterativo de ajuste de feixes altamente redundantes.

A redundância de imagens ocorre devido aos voos em baixas alturas e as sobreposições superiores ao recomendado na fotogrametria convencional (Westoby et al., 2012). Antes das imagens serem ajustadas, aproximações de suas orientações são conseguidas utilizando os dados do IMU da aeronave (Gini et al., 2013).

A resolução espacial das ortoimagens varia de acordo com a altura de voo e da câmara fotográfica utilizada, no geral, devido as baixas alturas dos voos, a resolução espacial compreende valores centimétricos. A qualidade da georreferência varia com o método de posicionamento por GNSS utilizado, quando se utiliza posicionamento por ponto simples a precisão apresenta valores na ordem de metros. Para alcançar alta precisão, menos que um *picture and element* (pixel) da imagem, é necessário coletar ponto de controle com GNSS topográfico ou geodésico (Laliberte et al., 2011c).

O uso dessas ortoimagens em análises quantitativas implica na sua calibração radiométrica. Em imagens obtidas por câmaras não métricas o método de calibração linear empírico está sendo utilizado com frequência (Kelcey e Lucier, 2012). Para utilizar essa metodologia, é necessário inserir na área de estudo alvos da cor preta e branca antes do voo. A partir desses alvos são coletadas amostras de reflectâncias utilizando um espectroradiômetro. Nos locais dessas amostras são extraídos os valores dos pixels e com esses dados são ajustadas regressões lineares para cada banda. Os valores dos pixels são utilizadas como variáveis dependentes e as amostras de reflectância como independentes (Berni et al., 2009).

A facilidade na obtenção dos dados com VANT proporcionada pela flexibilidade nos voos tem beneficiado estudos de fenômenos que necessitam monitoramento, como, acompanhamento de áreas com movimento de massa (Niethammer et al., 2012), evolução de canais de rios (Flener et al., 2013) e simulação de inundação (Li et al., 2012). Outro benefício desse sistema está na possibilidade de imagear locais inacessíveis (Ezequiel et al., 2014). Na agricultura é possível detectar nas lavouras as invasões de plantas daninhas (Torres-Sánchez et al., 2014).

Na classificação de cobertura da terra, as imagens obtidas por VANT, estão sendo utilizadas para discriminar classes específicas, como o trabalho da Laliberte

et al. (2011a), com o objetivo de diferenciar espécies de pastagens, encontrando acurácias que variaram de 78% a 92%, para mosaicos de imagens adquiridos entre 6 a 8 cm de resolução espacial. A precisão geométrica dos mosaicos de imagens, utilizando os dados do GPS da aeronave ficaram entre 1 a 2 metros.

Já Gini et al., (2014) com intuito de distinguir entre espécies de árvores e arbustos utilizaram dois VANT, um com câmara na banda do visível e outro na banda do infravermelho próximo. Aplicando para isso o método de classificação máxima verossimilhança e o método não supervisionado ISODATA. O método não supervisionado resultou em uma acurácia global de 50% e o método máxima verossimilhança 80%. Os autores relatam que não foi possível distinguir todas as classes.

Outro trabalho com o propósito de diferenciar classes a nível de espécie foi realizado por Flynn e Chapra (2014), no qual os autores utilizaram um VANT com câmara na banda do visível para identificar algas *Cladophora* no Rio Clark Fork, nos EUA. A área foi sobrevoada 18 vezes, as imagens para cada voo foram unidas e georreferenciadas, a partir dos mosaicos de imagens foram aplicados os classificadores, *Adaptive Cosine Estimator* (ACE) e o *Spectral Angle Mapper* (SAM). Resultando respectivamente nos valores 0,82 e 0,84, para o coeficiente de Tau. Os autores também comentam que o sensoriamento remoto óptico com VANT é uma promessa para completar medições precisas espacialmente, e multi-temporais de algas ou de vegetação submersa em rios rasos, com baixa turbidez.

Trabalhos como o de Fuyi et al. (2012) que consideram classes mais distintas, não são comuns em artigos sobre classificação de imagens coletadas por câmaras de baixo custo acopladas a VANT. Nesse trabalho, Fuyi et al. (2012) utilizaram imagens coletadas com uma câmara nas bandas do visível acoplada a um VANT, com o objetivo de diferenciar as classes vegetação, água, solos, urbanos e uma classe para o restante. Para isso foram avaliados dois métodos de classificação, redes neurais artificiais e máxima verossimilhança, os valores da acurácia global encontrados foram 89% e 87%, respectivamente. Os autores ainda comentam que o uso de uma câmara convencional a bordo de um VANT, pode fornecer informações úteis para o planejamento e desenvolvimento de pequenas áreas de cobertura.

Imagens coletadas por VANT também possibilitam a elaboração de Modelos Digitais de Elevação (MDE). Como identificado no trabalho de Mancini et al. (2013), que teve como objetivo reconstruir a topografia de um ambiente costeiro. Os autores

encontraram diferentes densidades de pontos para distintas superfícies. Em texturas uniformes, como em áreas com areia houve uma redução do número de pontos. Nesse mesmo estudo é sugerido o mínimo de 10 imagens sobrepostas para obter resultados confiáveis, comparáveis a levantamentos com *Light Detection And Ranging* (LIDAR).

## 2.3 Análise de imagens baseada em objetos

### 2.3.1 Análise baseada em objetos versus baseada em pixel

Na análise baseada em objetos, a unidade de processamento não são pixels isolados, e sim grupos de pixels, denominados de regiões ou segmentos. A utilização dessa unidade nos processamentos propicia vantagens devido à quantidade de informações adicionais que podem ser derivadas desses objetos. Nos processamentos utilizando pixels individuais o vetor de informação é composto pelas bandas, não fazendo uso do conceito espacial (Blaschke et al., 2010). Diferentemente, dos objetos que possibilitam cálculos estatísticos dos pixels agrupados, por exemplo, valores médios das bandas e/ou de suas texturas, além de informações geométricas e contextuais (Myburgh e Nieker, 2013).

Dean et al. (2003), comparando OBIA com classificação baseada em pixel para diferentes satélites e sensores, concluíram que a OBIA foi superior à classificação baseada em pixel quando a resolução espacial da imagem aumenta.

Kamal et al. (2011) avaliaram dois classificadores baseados em pixel, *Spectral Angle Mapper* (SAM) e o Modelo Linear de Mistura Espectral (MLME) com a OBIA disponível no programa *Definiens Developer 7* na classificação de nove classes de cobertura da terra, sendo que três são de espécies de mangue. O conjunto de dados foi formado por 30 bandas com resolução espacial de 4 m, coletadas com uma câmara métrica hiperespectral. Avaliando as classificações obtidas a partir de 400 amostras de verdade de terreno, encontraram o valor de 0,67 para o índice kappa utilizando OBIA. Já para SAM e MLME, encontraram os valores 0,57 e 0,41 para o índice kappa, respectivamente. Concluíram, com isso, que a

abordagem baseada em objetos foi mais adequada para classificar espécies de mangue.

Em imagens obtidas por VANT, a OBIA também se mostrou um método eficiente, como o apresentado por Laliberte et al. (2010). Nesse trabalho os autores avaliaram a aplicação de imagens coletadas com VANT e a OBIA no inventário de espécies de pastagens. Também foram realizadas medições no campo para determinação das espécies de pastagem. Avaliando as estimativas geradas com imagens e os dados de campo, encontraram um  $R^2$  que variou de 0,86 a 0,98. A acurácia global para os mosaicos variou de 83% a 86%. Os autores relatam que o sistema VANT e a OBIA podem complementar ou até mesmo substituir algumas medições a campo.

### **2.3.2 Métodos de segmentação**

O primeiro momento da OBIA é a formação das regiões ou segmentos, esses processos são produzidos por métodos de segmentação. Esses métodos podem ser divididos em duas abordagens: a segmentação baseada em descontinuidade dos níveis digitais (ND) e a segmentação baseada em similaridade dos ND. A segmentação baseada em descontinuidades tem como finalidade dividir a imagem, considerando as mudanças bruscas de intensidade dos ND. Podem ser considerados como descontinuidades: pontos isolados, linhas e bordas entre os objetos. Já a segmentação por similaridade visa à divisão da imagem em regiões ou segmentos que apresentam intensidade de ND homogêneos (Batz e Schaepe, 2000).

A detecção dos pontos, linhas ou bordas é efetuada por meio de uma janela de convolução que percorre a imagem à procura de mudanças de intensidades na imagem (descontinuidades). Os filtros de Sobel ou de Prewitt são exemplos de filtros de detecção de bordas, em que a janela de convolução recebe valores diferenciados, com intuito de identificar as bordas entre objetos de uma imagem (Blaschke, 2010).

Na detecção de regiões, as técnicas utilizadas têm como proposta agrupar pixels que possuam propriedades similares, essas propriedades podem assumir

valores do nível de intensidade, cor ou textura. Os métodos de segmentações mais utilizados para detecção das regiões similares são os de crescimento de regiões (*region growing*), de divisão e fusão de regiões (*split and merge*) e de divisor de águas (*watershed*) (Turker e Sumer., 2008).

Na segmentação por crescimento de regiões, o processo inicia a partir de um conjunto de pixels sementes, os pixels vizinhos que possuem propriedades similares são agrupados aos pixels sementes, isso faz com que as regiões cresçam (Espindola, 2006). Os pixels sementes podem ser gerados de forma aleatória, determinística ou pelo usuário. A decisão para agrupar ou não o pixel é determinada por um limiar definido pelo usuário, o pixel será anexado na região, caso a diferença dos ND entre o pixel semente e o seu vizinho seja menor que o limiar (Equação 1), ou seja,

$$R = \left\{ \begin{array}{l} \text{VERDADEIRO, se } |f(x, y) - f(r, s)| \leq T \\ \text{FALSO, caso contrário} \end{array} \right\} \quad \text{Equação 1.}$$

em que  $R$  é a região,  $f(r, s)$  representa o pixel semente,  $f(x, y)$  os pixels conectados ao pixel semente e  $T$  é o limiar definido pelo usuário.

Esse processo ocorre até que todos os pixels estejam contidos em uma região, alguns algoritmos possuem um parâmetro que restringe o número de iterações. A dificuldade desse método está na escolha dos pixels sementes, pois eles podem não representar as regiões de interesse (Adams e Bischof, 1994).

O método de divisão e fusão de regiões combina as técnicas de crescimento de regiões e a de divisão de regiões. O princípio desse método é realizar um particionamento na imagem. Uma alternativa é dividir a imagem em várias regiões arbitrárias e disjuntas e, posteriormente, aplicar uma junção e/ou divisão das regiões. A junção é necessária para evitar que regiões adjacentes e similares fiquem separadas. O método só finaliza quando nenhuma divisão ou fusão for mais possível (Chaudhuri e Agrawal, 2010).

Para o método divisor de águas, a imagem deve ser interpretada como uma superfície topográfica, no qual os ND podem ser entendidos como valores altimétricos, formando vales e montanhas. A formação das regiões é dada partindo do mínimo local até a linha de cumeada, gerando nesse processo bacias hidrográficas que são entendidas como regiões homogêneas. O resultado obtido por

essa segmentação pode ser afetado por ruídos na imagem ou por irregularidades das bordas das feições da imagem, fazendo com que ocorra um grande número de regiões (Turker e Sumer, 2008).

A partir desses segmentadores, são desenvolvidos novos métodos. Esses métodos, entretanto, não se baseiam em apenas uma característica, e sim em duas ou mais, um bom exemplo disso é o método disponível no programa comercial *eCognition*. O algoritmo implementado nesse programa considera cada pixel como um objeto, e iterativamente, pares de objetos são unidos em objetos maiores (Blaschke, 2010).

A condição para unir os objetos é baseada em três parâmetros: escala, forma e compacidade. O valor de escala é referente ao tamanho possível para as regiões, quanto maior o valor para esse parâmetro, mais liberdade é dada ao crescimento da região. Já o parâmetro da forma considera a união de dois parâmetros, compacidade e suavidade. Compacidade é definida entre a razão da área da região com o raio da circunferência circunscrita. A suavidade se refere aos limites existentes entre as regiões, sendo que, quanto mais limites existentes, maior é o índice da forma (Blaschke, 2010).

Programas livres e gratuitos, como o Spring, desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE), também estão disponíveis para serem utilizados na OBIA. Esse programa utiliza um método multirresolução que se baseia na técnica crescimento de regiões ou divisor de águas na segmentação das imagens. Sendo que são necessários dois parâmetros para formar as regiões, o limiar de similaridade e o número mínimo de pixels.

Em um estudo realizado por Meinel e Neubert (2006), o método multirresolução disponível no Spring, utilizando a técnica crescimento de regiões foi comparado com outros seis algoritmos de segmentações de diferentes programas. Nesse contexto, Spring apresentou o segundo melhor resultado em termos de qualidade, ficando atrás apenas do programa *eCognition*, sendo que o Spring é um programa gratuito e com código aberto.

O algoritmo de segmentação do Spring inicia agrupando pixels vizinhos semelhantes em regiões. Duas regiões vizinhas,  $R_i$  e  $R_j$ , são mescladas se cumprirem as seguintes condições:

- 1 - Condição do limiar:  $dist(R_j, R_i) \leq T$ ,
- 2 - Condição dos vizinhos 1: Se,  $R_j \in N(R_i)$  e  $dist(R_j, R_i) \leq dist(R_k, R_i)$ , então,  $R_k \in N(R_i)$ .
- 3 - Condição dos vizinhos 2: Se,  $R_i \in N(R_j)$  e  $dist(R_j, R_i) \leq dist(R_k, R_j)$ , então,  $R_k \in N(R_j)$ .

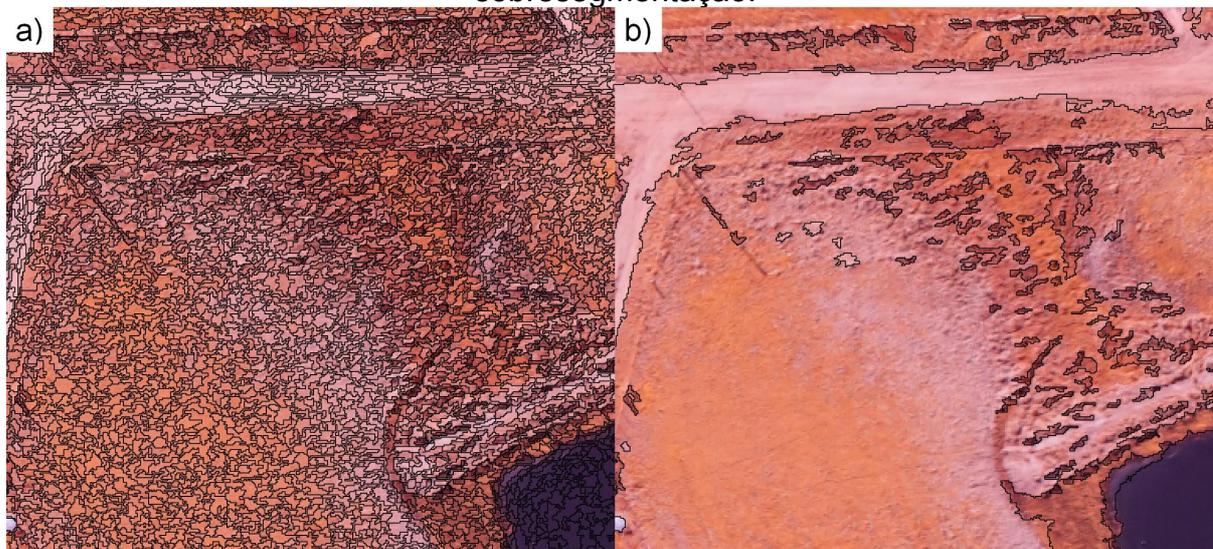
em que  $T$  é o valor do limiar de similaridade,  $dist(R_i, R_j)$  é distância Euclidiana entre os níveis de cinza médios das regiões,  $R_k$  é a região vizinha e  $N(R)$  é o conjunto de regiões vizinhas da região  $R$ .

As regiões com área menor que a preestabelecida pelo limiar de área são agrupadas aos seus vizinhos mais semelhantes (Bins et al., 1996).

Teodoro et al. (2014), com o objetivo de classificar a cobertura da terra de uma imagem obtida por VANT, utilizaram diferentes valores para os parâmetros de segmentação crescimento de regiões do Spring. Os autores observaram que as melhores classificações foram encontradas para os menores valores de similaridade e para os maiores valores do número mínimo de pixels.

Outro aspecto desses parâmetros está na questão de que valores muito altos para o limiar de similaridade podem causar sobresegmentação, enquanto valores baixos podem resultar em um subsegmentação (Espindola, 2006). A Figura 2a ilustra o subsegmentação causado por um valor limiar baixo, sendo possível observar regiões semelhantes divididas em várias outras. Já a Figura 2b representa um sobresegmentação das regiões, ou seja, uma região representando diferentes tonalidades na imagem. Para a classificação da cobertura da terra, utilizando essas regiões, um sobresegmentação impediria essa classificação, porque duas ou mais classes de cobertura da terra estão na mesma região

Figura 2 - Regiões formadas pela segmentação, a) subsegmentação e b) sobresegmentação.



Esses problemas podem afetar diretamente as etapas subsequentes da OBIA, porque a segmentação é uma etapa crítica dessa abordagem (Baatz e Schaepe, 2000). Devido a isso, métodos de avaliação para imagens segmentadas também foram desenvolvidos. Basicamente essas avaliações são quantitativas e estão divididas em métodos empíricos de discrepância, como em métodos de avaliação que consideram o sob e sobresegmentação das regiões. Os métodos empíricos analisam o número de pixels erroneamente segmentados, considerando, nesse caso, segmentos delineados por especialistas (Estrada e Jepson, 2005).

Neubert e Neimel (2006) utilizaram um índice de forma para avaliar diferentes programas e métodos de segmentação. Para isso, foram delimitadas regiões por um especialista e utilizadas para selecionar as regiões obtidas pelos segmentadores que tinham mais de 50% de sobreposição, com isso foi calculada a razão do índice de forma dessas regiões sobrepostas. Utilizando essa medida na avaliação, conseguiram identificar que os algoritmos analisados sofreram com a falta de estabilidade no processo de segmentação.

Feitosa et al. (2006) utilizaram regiões delimitadas por um especialista para selecionar automaticamente os melhores parâmetros na segmentação. O método proposto pelos autores procura os parâmetros da segmentação que minimizam a função de ajuste entre regiões verdadeiras com as obtidas pela segmentação. Os resultados obtidos se mostraram promissores na seleção de parâmetros, porém, foi encontrada mais que uma solução e também um baixo desempenho no

processamento.

Dessa forma, a seleção de uma técnica de segmentação vai depender do tipo de dados a serem analisados e da área de aplicação, por outro lado a qualidade dos resultados obtidos com a segmentação é determinada pela finalidade do estudo e pela estratégia de agrupamento (Baatz e Schaepe, 2000).

## **2.4 Classificadores**

### **2.4.1 Paramétricos e não paramétricos**

A classificação da cobertura da terra por meio de regiões tem mostrado melhores resultados do que as baseadas em pixel. Dentre as melhorias, está a facilidade de interpretação da classificação, pois pixel a pixel apresenta a sensação de “sal e pimenta” (Aplin e Smith, 2011).

Em imagens de alta resolução espacial, o emprego da classificação baseada em pixels apresenta resultados ineficientes devido à alta variabilidade espectral dos objetos e ao número de classes presentes nessas imagens (Johansen et al., 2010).

Na OBIA a classificação é uma etapa subsequente à segmentação da imagem, em que as regiões são submetidas a uma classificação (Aplin e Smith, 2011). Os classificadores por regiões se baseiam em simular o comportamento de um fotointérprete, considerando, para isso, atributos espectrais e espaciais (Blaschke, 2010).

Um método tradicional de classificação aplicado a imagens de sensoriamento remoto é o da máxima verossimilhança (MaxVer). Esse classificador quantifica as médias e as matrizes de covariâncias das amostras das classes e, a partir desses valores e dos valores da região a ser classificada, calcula a probabilidade da região pertencer a cada classe, o maior valor de probabilidade obtido é a classe da região. A probabilidade é calculada pela Função de Densidade Probabilística (FDP), essa função supõe que os atributos preditores que representam as classes seguem uma distribuição normal (Myburgh e Niekerk, 2013).

Na Figura 3a está representado a FDP de duas classes para a banda1, que

foi gerada aplicando a FDP, utilizando como parâmetros: as médias, as variâncias e as covariâncias dos dados que representam as classes. Já a Figura 3b ilustra as fronteiras de decisão do método MaxVer para as duas classes, na qual estão representadas pelas FDP de dois atributos. O valor da região representada pelo “x” seria submetido ao produto das FDP dos atributos para cada classe. O resultado com maior probabilidade, seria a classe da região. No exemplo da Figura3b, a região seria classificada como classe B. As fronteiras de decisão desse método podem assumir apenas formas elípticas.

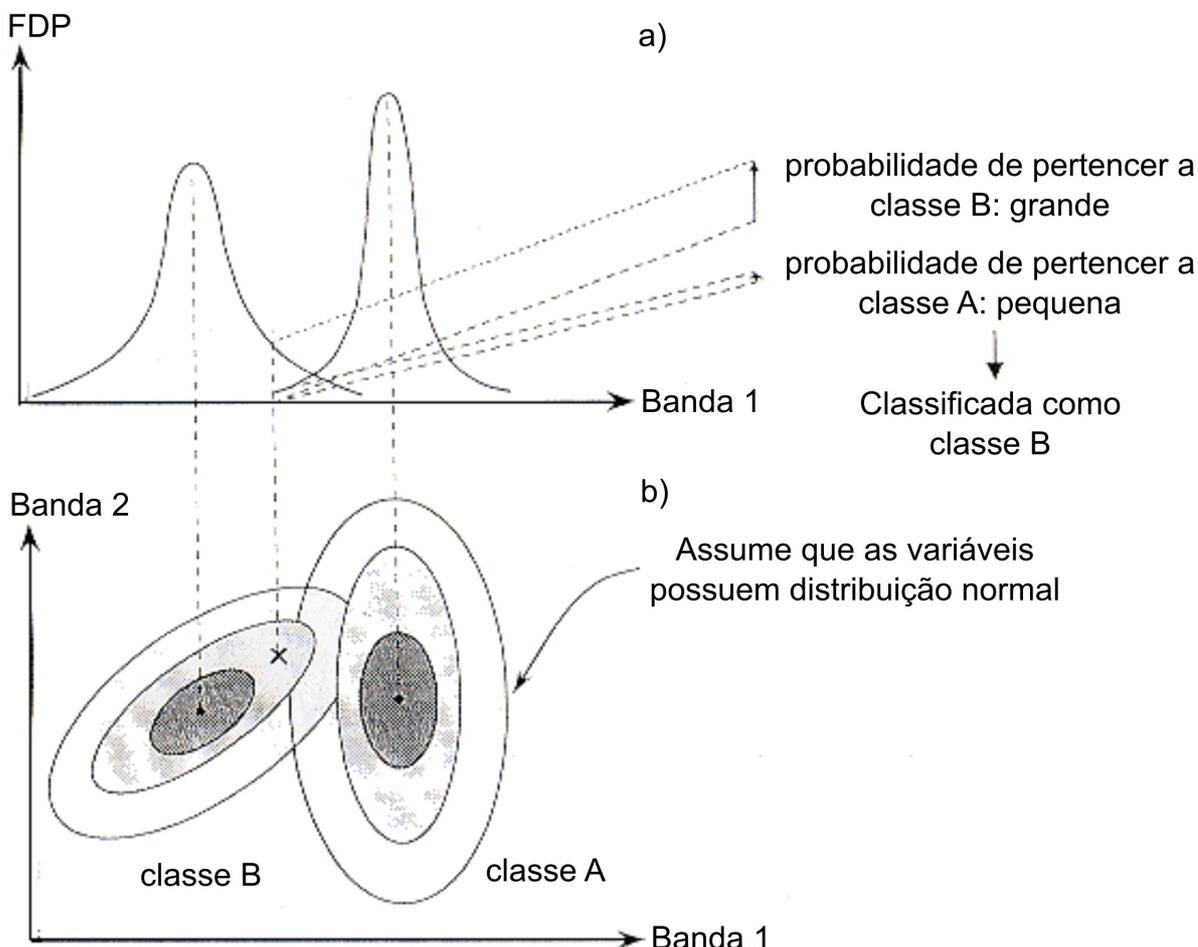
Outro método que utiliza parâmetros estatísticos para a classificação das regiões é o da distância de Bhattacharyya, esse método faz uso dos mesmos princípios do MaxVer, utilizando os valores das médias e da matriz de covariâncias das classes para classificar a região. A distância de Bhattacharyya faz a mesma suposição sobre as amostras das classes, ou seja, considera-as como uma distribuição normal (Joshi et al., 2014).

O problema é que alguns atributos preditores não podem ser representados apenas por medidas estatísticas, além de não apresentarem uma distribuição normal em relação às classes.

Na classificação da cobertura da terra utilizando regiões, outro agravante é a quantidade de atributos gerados. Além dos valores médios das bandas e das texturas, são utilizados atributos geométricos como: área, índice de forma, ajuste retangular e assimetria. No final, podem ser utilizadas centenas de atributos preditores na classificação, e muitos desses são correlacionados ou não são informativos (Laliberte et al., 2012). Myburgh e Niekerk(2013), analisando o desempenho do classificador MaxVer na OBIA, concluíram que, ao aumentar o número de atributos preditores, o método por MaxVer diminui o seu desempenho na classificação.

Devido a isso, são vistos mais trabalhos que utilizam métodos para reduzir a dimensionalidade dos dados e de algoritmos de classificação não paramétricos. Os trabalhos de Chutia et al. (2014) e de Fernandes et al. (2014), que utilizaram algoritmos de mineração de dados, são exemplos desses estudos. Mineração de dados pode ser entendida como uma área do conhecimento que abrange as técnicas de reconhecimento de padrões, estatística, banco de dados e visualização para conseguir extrair informações de grandes conjuntos de dados (Hand et al. 2001).

Figura 3 - Representação da classificação paramétrica, a) FDP das classes e b) as fronteiras de decisão das classes, geradas pela FDP



Os métodos de classificação no processo de mineração de dados são considerados não paramétricos, esses métodos não demandam que os dados sigam alguma distribuição em particular, ou seja, os parâmetros estatísticos não definem o comportamento de uma classe como um todo. Dentre as classificações não paramétricas comumente utilizadas, estão as Redes Neurais Artificiais (RNA) (Foody e Arora, 1997), Máquina Vetor de Suporte (MVS) (Chutia et al., 2014) e Árvore de Decisão (AD) (Friedl e Brodley, 1997).

As AD apresentam algumas vantagens no processo de classificação, as quais podemos citar: facilidade de interpretação dos seus resultados, baixo tempo de processamento na construção do modelo, não demanda que os dados tenham distribuições normais e também por conseguir trabalhar com dados medidos em distintas escalas (Friedl e Brodley, 1997). Assim, as AD são conceitualmente técnicas simples de análise de dados, mas poderosas e adequadas para a identificação de relações entre as variáveis em conjuntos de dados multivariados

(Kuhn e Johnson, 2013).

Essa técnica também possibilita a seleção dos atributos mais informativos, utilizando, para isso, as métricas de impureza, que também são utilizadas na construção da AD. Dentre essas métricas, podemos citar: Gini, Entropia e Razão do Ganho.

#### 2.4.2 Árvore de decisão

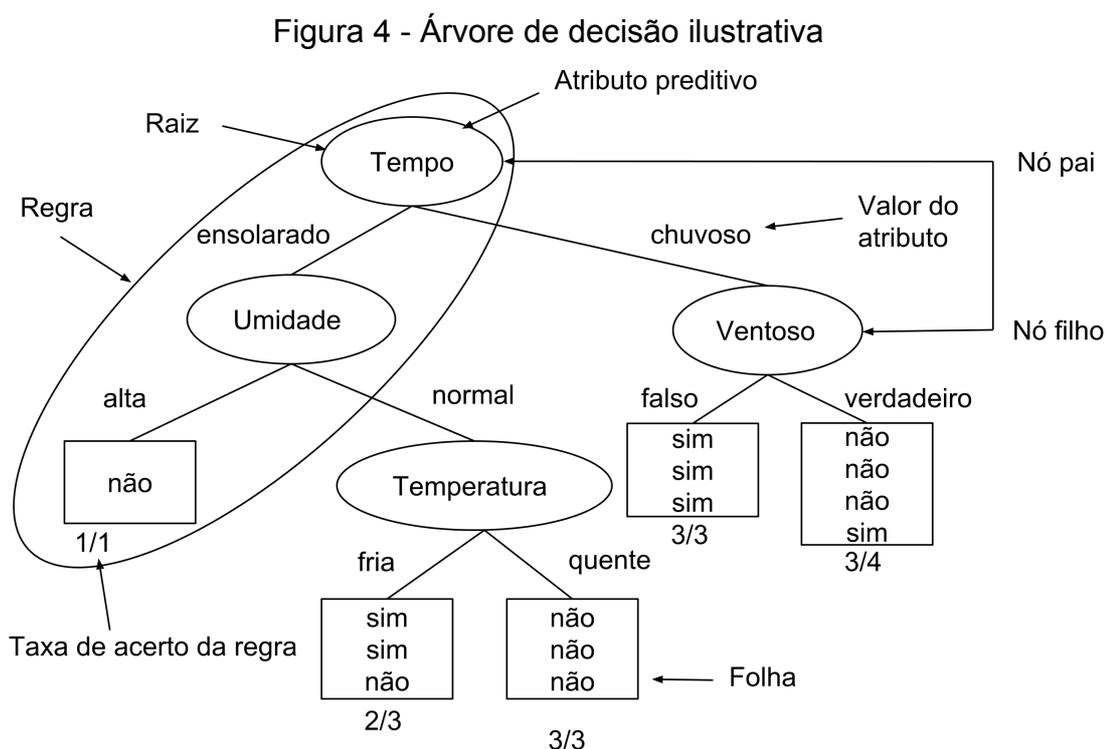
As AD conseguem cumprir os dois papéis, tanto servem como classificadores, como possibilitam selecionar atributos mais informativos. Hellesen e Matikainen (2013) utilizaram o método de CART na OBIA para diferenciar as classes arbustos (floresta), construções e solo (solo sem vegetação e com vegetação). Utilizando fotografias aéreas nas bandas do visível e infravermelho, juntamente com dados LIDAR, a acurácia global chegou a 96,7%.

Em estudo realizado por Laliberte et al. (2011b) com um sensor multiespectral acoplado em um VANT, foi utilizado o programa *eCognition* para gerar as regiões e o algoritmo CART para selecionar os atributos preditores mais informativos. Essas regiões foram classificadas utilizando o método de vizinho mais próximo. A partir dessa metodologia, os autores conseguiram classificar espécies de pastagens com uma exatidão global de 87%. Em outro estudo realizado por Laliberte et al. (2012), foram analisados três métodos de seleção de atributos para serem utilizados na OBIA. Nessa avaliação foram consideradas a facilidade de uso, a capacidade de reduzir os atributos de entrada e a exatidão da classificação após a remoção dos atributos selecionados. O método CART foi considerado pelos autores o que mais se adequou a esses critérios de avaliação.

Os modelos construídos por AD conseguem identificar essas relações entre a variável dependente e as múltiplas variáveis independentes por meio de um particionamento recursivo binário, em que os dados são divididos em grupos cada vez mais homogêneos ou nós, utilizando combinações das variáveis mais informativas que melhor explicam a variação da variável dependente (Quinlan, 1996).

Uma AD é construída de forma recursiva, ou seja, particiona o conjunto de

dados de treinamento em subconjuntos rotulados com classes únicas. O primeiro passo é selecionar o atributo do nó raiz, para isso gera-se um ramo para cada valor possível do atributo. Para os atributos preditores com tipo de dado contínuo, é necessário discretizar esses valores, isso é feito a partir do parâmetro mínimo de instâncias. Então, os exemplos são divididos em subconjuntos, esse procedimento é repetido recursivamente para cada ramo, usando apenas exemplos que chegam ao ramo considerado. O processo finaliza quando todos os exemplos do subconjunto do ramo têm a mesma classe ou quando o número de instâncias é menor que um limiar estabelecido. Também pode ser interrompido quando o critério de expansão dos nós não é satisfeito. Essa construção é um modelo chamado de *Top-Down*, ou seja, começa da raiz e vai para as folhas. Na Figura 4 está ilustrado um exemplo de uma AD construída para decidir se haverá jogo de tênis, representando uma árvore invertida (Figura 4) (Quinlan, 1989).



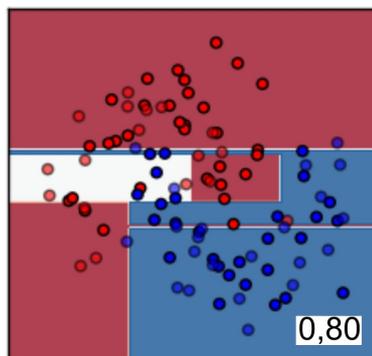
em que a Raiz: é o primeiro nó da árvore, aparece no topo dela; Atributo preditivo: é a variável analisada no nó (tempo, umidade, temperatura e ventoso); Nó: são todos os itens que aparecem na árvore (folhas, raiz e os nós de decisões); Folha: É o rótulo da classe encontrada para a regra, esses rótulos são do atributo

alvo, nesse caso, é o atributo Joga, que possui duas classes, sim ou não; Filhos: São os nós das ramificações (tempo nó pai e ventoso nó filho); Regra: É o caminho percorrido da raiz até um nó folha (Se, tempo = ensolarado e umidade = alta, então, classe = não); Teste de decisão: São os operadores ( $<$ ,  $>$ ,  $\leq$ ,  $\geq$  ou  $=$ ).

Os nós internos são onde ocorrem os testes sobre um atributo preditivo, os dois possíveis caminhos para o teste representam a ramificação da árvore. Essa ramificação pode assumir uma folha ou outro nó filho.

Os modelos por AD são interpretados como testes condicionais “Se-então”, cada regra pode ser convertida para esses testes condicionais e, com isso, facilitam a interpretação do modelo gerado. Esses modelos produzem uma decisão paralela aos eixos, criando formas retangulares, como ilustra a Figura 5, em que apresenta a separação dessas fronteiras em duas classes. As áreas das criadas pelas fronteiras podem apresentar qualquer tamanho de retângulo.

Figura 5 - Fronteiras de decisão da classificação por AD.



Fonte: [scikit-learn.org/](http://scikit-learn.org/)

Um dos primeiros algoritmos de indução por AD foi o ID3, desenvolvido por Quinlan (1989). Esse algoritmo escolhe o melhor critério de divisão da árvore, utilizando medidas de impureza. O grau de impureza é menor, quanto mais desbalanceada for a distribuição de classes, assim quando houver o mesmo número de instâncias para cada classe possível, o grau de impureza resultará em um valor máximo. Uma medida utilizada para quantificar a impureza é o Ganho da Informação (Equação 2), que usa o cálculo da Entropia para essa finalidade, tal medida resulta na quantidade de informação na unidade *bits*. Para avaliar a qualidade da divisão do conjunto de dados de treinamento, é necessário comparar o grau de entropia do

nó-pai (antes da divisão) com o grau de entropia dos nós-filhos (após a divisão). O atributo que resultar em um maior valor é escolhido como condição teste. O Ganho da Informação mede o grau de pureza. A Equação 3 representa o cálculo do ganho.

$$\text{Entropia (nó)} = - \sum_{i=1}^c p(i/\text{nó}) \cdot \log_2[p(i/\text{nó})] \quad \text{Equação 2.}$$

em que  $p(i/\text{nó})$  é a fração dos registros pertencentes à classe  $i$  no nó e  $c$  é o número de classes.

$$\text{Ganho} = \text{entropia}(\text{nó pai}) - \sum_{j=1}^n \left[ \frac{N(v_j)}{N} \text{entropia}(v_j) \right] \quad \text{Equação 3.}$$

em que  $n$  é o número de valores do atributo, ou seja o número de nós filhos,  $N$  é o número total de objetos do nó pai, e  $N(v_j)$  é o número de exemplos associados ao nó-filho  $v_j$ .

A medida de ganho da informação possibilita que um atributo sem informação sobre as classes seja selecionado, como pode acontecer com um atributo de identificação, ou seja, ele dá preferência para atributos com muitos valores possíveis (Quinlan, 1996).

Os algoritmos por AD se ajustam perfeitamente aos exemplos de treinamento, isso pode ser um problema quando os dados de treinamento contemplam valores ruidosos ou também quando os dados de treinamento não representam o conjunto de dados que se pretenda classificar. Esse ajuste em excesso é conhecido como sobreajuste (*overfitting*), isso resultará em uma árvore com pouco poder de generalização.

Uma forma de amenizar esses problemas é por meio da poda (*pruning*) da árvore, com objetivo de melhorar a taxa de acerto do modelo para o conjunto de dados não utilizados no treinamento (HAN, 2001). Os métodos de poda são classificados como pré-poda e pós-poda. A pré-poda acontece simultaneamente com a construção da árvore, nesse caso, o ganho da informação pode ser utilizado como critério de poda. Já a pós-poda acontece posteriormente à construção da árvore, tendo como objetivo a remoção de ramos que forneçam pouco poder de previsão por folha. Essa avaliação é feita analisando a frequência de casos representados

pelo ramo e a taxa de erro provocada pela sua poda. Se a substituição da subárvore por uma folha ou pelo seu ramo mais frequente ocasionar uma taxa de erro aceitável, então a subárvore é removida.

Um dos algoritmos mais utilizados para a classificação por AD é o C4.5, esse algoritmo é o sucessor do ID3. Com o C4.5 é possível utilizar atributos categóricos e contínuos, também permite o uso de valores desconhecidos para um atributo. O critério utilizado para medir a impureza é a razão do ganho (Equação 4). Para evitar o sobreajuste aos dados de amostras, esse algoritmo utiliza o método de pós-poda (Quinlan, 1996). O C4.5 é considerado um algoritmo do tipo “guloso”, ou seja, a partição dos dados é sempre em relação ao melhor passo avaliado localmente, não se preocupando se esse passo, juntamente com a sequência completa dos passos, irá resultar na melhor solução.

$$\text{Razão do ganho (nó)} = \frac{\text{ganho}}{\text{entropia}(\text{nó})} \quad \text{Equação 4.}$$

Na razão de ganho, não ocorre os mesmos problemas que o ganho da informação, porque, como a entropia está no denominador, valores iguais a zero, não definem a razão do ganho.

Carvalho et al. (2012) utilizaram o classificador por árvore de decisão C4.5, disponível no programa WEKA como J48, na etapa de classificação da cobertura da terra para uma imagem WorldView-2. Posteriormente à segmentação da imagem, as regiões geradas foram classificadas considerando diferentes valores para o parâmetro número mínimo de instâncias. Os melhores resultados foram obtidos utilizando o valor dois para esse parâmetro, apresentando um valor para o índice kappa de 0,83.

Novos algoritmos de AD estão sendo desenvolvidos e, dentre as preocupações, estão a construção do modelo e a seleção de atributos. Na nova versão do algoritmo C4.5, o C5.0.

As principais diferenças do C5.0 para seu antecessor foi em relação à incorporação de um método reforço (*boosting*) na determinação do modelo resultante e uma abordagem que possibilita selecionar um subconjunto de atributos mais informativos (*winnow*) para ser utilizado na construção da árvore.

O método *boosting* tem como finalidade gerar vários modelos, também

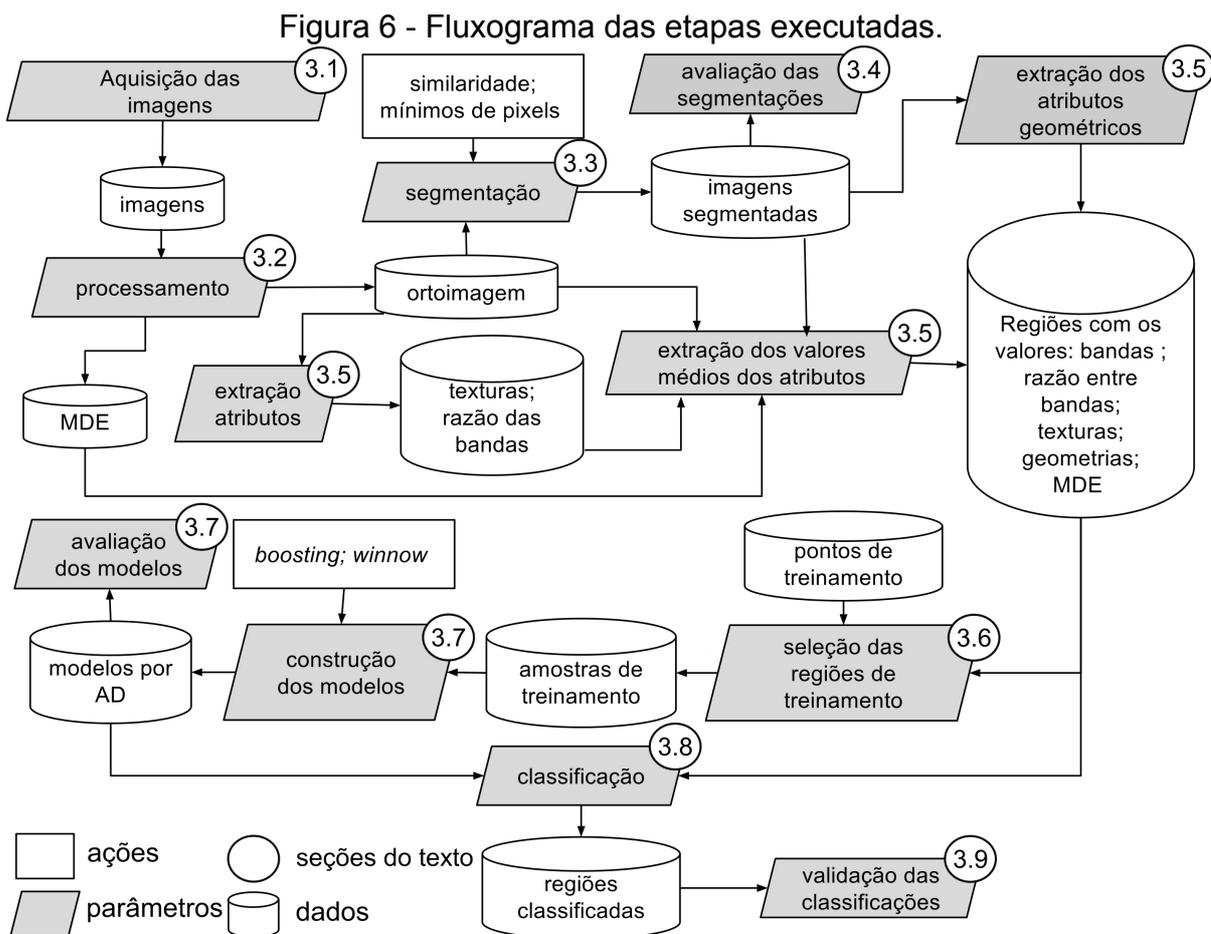
chamados de ensaios, ao invés de apenas um. O parâmetro *trial* controla o número de vezes que serão gerados os ensaios. Em cada construção é dada mais atenção às regras com maiores taxas de erros, tentando diminuir a taxa de erro do modelo no próximo ensaio (Quinlan, 2013).

Já a abordagem de seleção dos atributos mais informativos (*winnnow*) é efetuada dividindo aleatoriamente em duas partes iguais os dados de treinamento, posteriormente, com uma dessas partes é gerado o modelo por árvore (árvore teste), esse modelo tem como propósito avaliar a utilidade dos atributos preditores. Os atributos preditivos que não estão em nenhuma divisão da árvore são considerados sem importância e podem ser removidos do conjunto de dados. A outra parte das amostras de treinamento, que não foi utilizada para gerar o modelo é empregada para estimar a taxa de erro da árvore. A taxa de erro é calculada com e sem o atributo preditivo, caso essa taxa aumente sem o preditor, esse preditor continua no conjunto de dados. (Kuhn e Johnson, 2013).

O C5.0 tem mostrado ser um algoritmo mais rápido e mais preciso que o seu antecessor (Patil et al., 2012).

## MATERIAIS E MÉTODOS

Para a execução dos objetivos propostos nesse trabalho, foi definida a metodologia proposta no fluxograma apresentado na Figura 6.



### 3.1 Aquisição das imagens

A área estudo está situada na Estação Experimental da Universidade Federal do Rio Grande do Sul (UFRGS), no município de Eldorado do Sul, RS. Compreendida pelas coordenadas geodésicas 30° 5'9.32" sul, 51°41'3.98" oeste e 30° 5'45.19" sul e 51°40'31.11" oeste. O voo foi realizado nessa área, no dia 21 de julho de 2014, às 13 horas.

Para a realização do voo e a aquisição das imagens, foi utilizada uma câmara

Sony, modelo ILCE-7R, com resolução de 36,4 *megapixel* acoplada ao VANT Echar 20A, que é comercializado pela empresa brasileira XMobots. Esse equipamento foi adquirido pelo Programa de Pós-Graduação em Sensoriamento Remoto em 2014, a partir do Edital Pró-Equipamentos e financiado pela a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

O equipamento é composto por uma aeronave, uma estação de controle e um terminal de dados (Figura 7). A estação e o terminal de dados possibilitam o monitoramento do estado da aeronave, que possui dispositivo de localização e sistema inercial. O lançamento da aeronave é feito por uma catapulta e o pouso por um paraquedas.

Figura 7 - Aeronave Echar 20A e equipamentos auxiliares.



Fonte: <http://www.hezolinem.com>

A câmara utilizada coleta imagens nas bandas do azul (410 nm), verde e infravermelho próximo (IVP). Para capturar imagens na banda do IVP, foi removida a banda do vermelho e inserido um filtro no comprimento de onda 670 nm a 770 nm.

Como a câmara é não métrica, os dados de calibração da lente foram adquiridos antes do voo pelo programa Agisoft Lens. Esse programa possibilita aplicar um método automático de calibração, que utiliza um tabuleiro de xadrez como calibragem alvo. Com essa calibração, são determinados os parâmetros: distância focal ( $f_x$  e  $f_y$ ), coordenadas do ponto principal ( $c_x$  e  $c_y$ ) e distorções radiais ( $K_1$ ,  $K_2$ ,  $K_3$ ,  $P_1$  e  $P_2$ ). Para determinar as distorções radiais, é utilizado o método de

Brown (1966).

O voo foi realizado a uma altura de 450 metros, com recobrimento entre faixas de 80% e entre imagens de 60%. O tempo de voo foi de aproximadamente 27 minutos, capturando 429 imagens, com uma resolução espacial de aproximadamente 7 cm.

### 3.2 Processamento das imagens

Para o processamento das imagens, foi utilizado o programa PhotoScan da empresa AgiSoft. O PhotoScan possui um fluxo automatizado para processar as imagens, utilizando, para isso, algoritmos de visão computacional. Para melhorar o desempenho dos processamentos, o programa utiliza recursos da unidade de processamento (*Central Processing Unit* - CPU) e da unidade de processamento gráfico (*Graphics Processing Unit* – GPU) (Agisoft, 2015). As etapas seguidas no programa estão descritas a seguir:

**(a) Inserção dos dados:** no primeiro momento, foram inseridas as imagens com seus respectivos ângulos de atitude e suas coordenadas. Também foram informados os parâmetros de calibração da câmara obtidos pelo programa Agisoft Lens.

**(b) Alinhamento das imagens:** nessa etapa, são encontradas as características e os descritores correspondentes entre as imagens, as imagens correspondentes são definidas pelas coordenadas espaciais, que são capturadas pelo sistema GNSS da aeronave. Após isso, utilizando as características e os descritores correspondentes calcula-se as posições das imagens e determina-se o modelo de nuvem de pontos esparsos.

A nuvem de pontos possui, no seu conjunto de dados, os valores de ND das respectivas bandas e valores das elevações da superfície imageada. Esses pixels são transformados de uma projeção cônica para uma perspectiva ortogonal, ou seja, são ortorretificados. O processo de ortorretificação para toda a imagem é realizado na etapa da construção da malha triangular.

**(c) Otimização do alinhamento das imagens:** essa opção é executada para

melhorar a precisão nos cálculos dos parâmetros internos e externos da câmara, como corrigir eventuais distorções. Também é obtida a precisão da georreferência nessa otimização do bloco de imagens e em qual sistema de coordenadas que a ortoimagem será exportada.

**(d) Determinação da nuvem de pontos densa:** baseando-se nas posições estimadas das imagens e nos pontos esparsos, são determinados novos pontos de profundidade. Esses novos pontos são combinados em uma nuvem de pontos densa.

**(e) Construção da malha triangular:** a malha triangular foi gerada a partir da nuvem de pontos densa. Foi selecionada a opção *high* para o número de faces da malha, possibilitando a geração máxima no número de faces. Essa rede irregular de triângulos (*Triangular Irregular Network – TIN*) representa as elevações da superfície, a partir dela é obtido o Modelo Digital de Elevação (MDE) da área de estudo.

**(f) Exportação da ortoimagem:** a ortoimagem foi exportada no sistema de coordenada Universo Transverso de Mercator (UTM), fuso 22 e no sistema de referência WGS84, com uma resolução espacial de 15 cm. O valor da resolução espacial foi generalizado para facilitar as etapas de processamento. O valor do ND do pixel de saída foi calculado pela média dos valores sobrepostos.

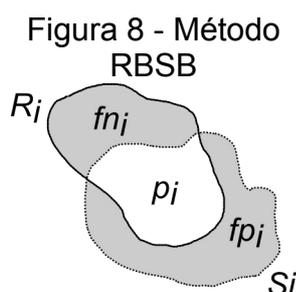
**(g) Exportação do MDE:** o MDE foi exportado nas mesmas configurações da ortoimagem.

### 3.3 Segmentação

A segmentação foi efetuada com o método multirresolução disponível no programa Spring, utilizando para isso a técnica crescimento regiões. Os resultados obtidos por esse método são sensíveis aos valores dos limiares de similaridade e de áreas (Espindola, 2004). Devido a isso, foram testados os valores de similaridade 1, 2, 5, 10, 15, 20, 30, 40 e 50, esses valores foram selecionados seguindo o trabalho de Teodoro et al. (2014). O valor do número mínimo de pixels foi estabelecido como 20, esse valor foi obtido de acordo com a escala de mapeamento pretendida, que nesse caso foi de 1:3000 (Oliveira, 2002).

### 3.4 Avaliação das segmentações

Para avaliar as segmentações geradas, foi utilizado o método *Reference Bounded Segments Booster* (RBSB), proposto por Feitosa et al. (2006). Segundo Ferreira (2011) essa métrica possui boa correlação com a percepção humana. A RBSB se baseia na comparação de regiões geradas por especialistas com regiões produzidas pelo algoritmo de segmentação. O valor ótimo para essa métrica seria zero, concluindo que a região de referência é exatamente igual à produzida pelo método de segmentação. Algumas considerações sobre esse método estão ilustradas na Figura 8.



em que  $R_i$  é o segmento delineado pelo especialista;  $S_i$  é o segmento resultante da segmentação;  $fn_i$  é o número de pixels de  $R_i$  que não pertencem a  $S_i$ , sendo chamados de falsos negativos;  $p_i$  são os pixels que se sobrepõem;  $fp_i$  é o número de pixels de  $S_i$  que não pertencem a  $R_i$ , sendo chamados de falsos positivos.

A Equação 5 ilustra o método de avaliação.

$$R_{RBSB} = \frac{1}{N} \sum_{i=1}^n \frac{(fn_i + fp_i)}{\$(R_i)} \quad \text{Equação 5.}$$

em que  $\$( )$  é área do segmento delineado pelo especialista;  $N$  número total de pixels.

As regiões de referência, delineadas por um especialista, foram elaboradas em uma escala 1:1000 sobre toda a área de estudo, sobre as classes: pastagem,

construção, árvore e sombra. Os locais onde foram geradas as regiões foram selecionados por apresentarem um limite bem definido. Também foram avaliados os valores médios das áreas das regiões para cada imagem segmentada. Para realizar essa avaliação nas imagens segmentadas, foi desenvolvida uma rotina na linguagem de programação Python 2.7, que está no Apêndice A. O desenvolvimento da rotina foi auxiliado pelas bibliotecas de programação:

**(a) *Geospatial Data Abstraction Library (GDAL)*:** Possibilita acessar as informações das imagens segmentadas e convertê-las para matrizes compatíveis com Numpy.

**(b) *Numpy*:** É uma biblioteca de computação científica, que facilita os cálculos matriciais.

**(c) *Operating System (OS)*:** Módulo para acessar o sistema operacional, utilizando essa biblioteca foi possível criar uma função para acessar todas as imagens em uma pasta de arquivo.

### **3.5 Extração dos atributos preditores**

Os seres humanos ao interpretarem imagens de satélites visualmente, consideram intuitivamente o contexto, limites, forma e variação dos tons de cores para distinguir os objetos. Os atributos preditivos têm como objetivo representar essas informações das imagens e, com isso, facilitar a classificação desses objetos (Blaschke, 2010). Na classificação da cobertura da terra utilizando a abordagem baseada em objetos, são usualmente adotados atributos espectrais, texturais e geométricos. Neste trabalho os atributos utilizados estão descritos nos subitens abaixo.

#### **3.5.1 Atributos espectrais**

O conjunto de dados espectrais é referente à radiância refletida dos objetos. Os dados capturados da radiância dependem diretamente do sensor. Neste trabalho

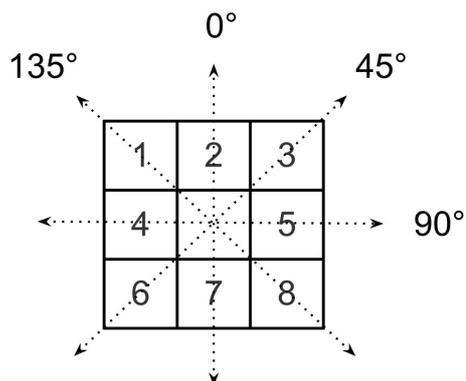
foi utilizado um sensor que coleta imagens nas bandas do azul, verde e do infravermelho próximo (IVP). A partir desses dados, foram derivadas as razões entre as bandas do IVP com azul ( $r_{ivp\_a}$ ), como a razão do IVP com o verde ( $r_{ivp\_v}$ ). Também foi calculada a razão da banda do verde com a azul ( $r_{v\_a}$ ). As razões entre as bandas foram utilizadas porque possibilitam a redução de ruídos, como diferenças de iluminação solar, sombras de nuvens e variações topográficas (Jensen, 2009).

### 3.5.2 Atributos texturais

Os atributos de textura descrevem os arranjos espaciais dos pixels e são úteis em análise de imagens com alta resolução espacial. A textura da imagem pode ser definida como o padrão das variações de brilho ou de níveis de cinza dentro de uma imagem ou dentro de uma região da imagem (Karathanassi, 2000). Os algoritmos que são utilizados na análise de textura podem ser divididos em estatísticos, geométricos, baseados em modelos e em processamento de sinal.

Neste trabalho foi utilizado o método estatístico de segunda ordem, que utiliza a matriz de coocorrência na extração das texturas. A matriz de coocorrência dos níveis de cinza (*Grey Level Cooccurrence Matrix* – GLCM) pode ser entendida como uma tabulação das possíveis combinações dos valores de intensidades dos pixels que ocorrem em uma imagem. De modo geral, a matriz de coocorrência pode ser especificada por uma matriz de frequências relativas, na qual dois elementos de texturas vizinhas, separados por uma distância  $d$  em uma orientação  $\theta$ , ocorrem na imagem (Haralick, 1979). Os elementos são os pixels, e as propriedades são os níveis de cinza. As distâncias podem assumir qualquer valor, já os ângulos de análise são restritos, conforme ilustra a Figura 9.

Figura 9 - Ângulos de análises



A construção da GLCM inicia-se pela determinação da matriz de frequências dos pares de níveis de cinza. Para a imagem representada na Figura 10, são encontrados seis níveis de cinza. Supondo que a distância de análise é um pixel e a orientação é 90°, foram obtidas, então, as frequências dos pares de níveis de cinza conforme a Tabela 2.

Figura 10 - Imagem com seis níveis de cinza.

1	2	4	6
2	3	4	5
3	2	6	5
1	4	6	5

Na Tabela 2 está a frequência em que os pares dos valores dos pixels aparecem na imagem, as cores destacam os dois exemplos, um na cor laranja e a outro na cor azul. Para esses pares de níveis de cinza, foram encontrados o valor 1 e 2, porque a busca é nos dois sentidos, esquerda e direita, numa direção horizontal (90°).

Tabela 2 - Matriz de frequência dos pares de pixels da Figura 10, para uma distância de um pixel e ângulo de 90°.

ND	1	2	3	4	5	6
1	0	1	0	1	0	0
2	1	0	2	1	0	1
3	0	2	0	1	0	0
4	1	1	1	0	1	2
5	0	0	0	1	0	2
6	0	1	0	2	2	0

O último passo para determinar a GLCM é calcular a matriz quadrada de probabilidade, como ilustra a Equação 6. A GLCM também é denominada de matriz normalizada, porque divide o valor da célula pela soma total dos valores. A matriz de coocorrência sempre será uma matriz quadrada e o número de linhas e colunas correspondente ao número de cinzas possíveis na imagem. Uma imagem de 8 *bits* são 256 níveis de cinza, portanto, a matriz terá 256 linhas e colunas.

$$P_{i,j} = \frac{M_{i,j}}{\sum_{i,j=0}^{N-1} (M_{i,j})} \quad \text{Equação 6.}$$

em que  $i$  é o número da linha e,  $j$  é o número da coluna;  $M$  é o conteúdo da célula  $(i, j)$  e  $N$  é o número de linhas ou colunas, porque  $M$  é uma matriz quadrada.

Aplicando a Equação 6 na matriz de frequências dos pares de níveis de cinza, são obtidos os valores conforme a Tabela 3. Esses valores foram calculados dividindo o valor de cada célula pelo valor 24 (soma total).

Tabela 3 - Matriz de coocorrência calculada a partir da matriz de frequências.

ND	1	2	3	4	5	6
1	0	0,047	0	0,047	0	0
2	0,047	0	0,083	0,047	0	0,047
3	0	0,083	0	0,047	0	0
4	0,047	0,047	0,047	0	0,047	0,083
5	0	0	0	0,047	0	0,083
6	0	0,047	0	0,083	0,083	0

Na prática a GLCM não é calculada sobre toda a imagem, geralmente são utilizadas janelas com tamanhos pré-definidos, como 3x3, 5x5 ou 7x7. Essa janela é utilizada para percorrer a imagem e definir a GLCM, posteriormente, é extraído para o pixel central algumas características de textura. As características de texturas analisadas neste trabalho foram o Momento Angular de Segunda Ordem (MASO - *Angular Second Moment*), correlação, entropia e contraste.

Essas texturas foram extraídas a partir da ferramenta *r.texture* do programa GRASS-GIS 6.4. para a banda do IVP. A banda foi utilizada porque apresentou uma melhor distinção visual entre as feições. Como janela de análise, foi utilizado o tamanho 3x3 e para orientação, os ângulos 0, 45, 90 e 135. Segue abaixo uma descrição dos atributos de texturas.

Momento Angular de Segunda Ordem é definido como uma medida de homogeneidade local dos níveis de cinza em uma imagem. Supondo que uma imagem seja homogênea, serão observadas baixas entradas de alta magnitude na matriz de coocorrência. A Equação 7 descreve o cálculo do MASO.

$$MASO = \sum_{i,j=0}^{N-1} P_{i,j}^2 \quad \text{Equação 7.}$$

em que  $P_{i,j}$  é o valor normalizado do ND para os pixels  $i$  e  $j$ ,  $N$  é o número de linhas ou de colunas.

A correlação (Equação 8) representa a dependência linear dos níveis de cinza

em uma imagem. Para uma imagem em que há certa ordenação local dos níveis de cinza, o valor da correlação é alto.

$$\text{correlação} = \sum_{i,j=0}^{N-1} P_{i,j} \left[ \frac{(i-\mu_i)(i-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad \text{Equação 8.}$$

em que  $i$  é a identificação da linha,  $j$  é a identificação da coluna,  $P_{i,j}$  é valor normalizado do ND para os pixels  $i$  e  $j$ ,  $\mu_i$  é a média dos ND para a linha  $i$ ,  $\mu_j$  é a média dos ND para a coluna,  $\sigma_i^2$  é a variância dos ND para a linha  $i$ ,  $\sigma_j^2$  é a variância dos ND para coluna  $j$  e  $N$  é o número de linhas ou de colunas.

A entropia pode ser entendida como o grau de dispersão dos níveis de cinza, também é utilizada como medida de homogeneidade. Seu valor é alto quando os valores da matriz de coocorrência são iguais. A entropia pode resultar em valores baixos quando a concentração de valores na diagonal é alto ou quando as entradas na matriz de coocorrência possuem valores baixos. A Equação 9 descreve o cálculo da entropia.

$$\text{entropia} = \sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j}) \quad \text{Equação 9.}$$

em que  $\ln$  é o logaritmo natural,  $P_{i,j}$  é valor normalizado do ND para os pixels  $i$  e  $j$ , e  $N$  é o número de linhas ou colunas.

O contraste ou variância são medidas que expressam a variação local dos níveis de cinza em uma imagem. Valores baixos para essa medida significam que os níveis de cinza da imagem analisada estão próximos da média. A fórmula para o cálculo do contraste está descrito na Equação 10.

$$\text{contraste} = \sum_{i,j=0}^{N-1} P_{i,j} (i-j)^2 \quad \text{Equação 10.}$$

em que  $i$  é a identificação da linha,  $j$  é a identificação da coluna,  $P_{i,j}$  é valor normalizado do ND para os pixels  $i$  e  $j$ , e  $N$  é o número de linhas ou colunas.

### 3.5.3 Modelo Digital de Elevação

As imagens coletadas por VANT possibilitam a geração de nuvem de pontos com elevações, esses pontos interpolados resultaram no Modelo Digital de Elevação (MDE). A nuvem de pontos foi gerada no programa Photoscan e interpolada pela técnica de redes de triângulos irregulares com função de primeira ordem no mesmo programa. A área de estudo possui um desnível de aproximadamente 18 metros entre o local mais alto com mais baixo, considerando as medidas sobre o terreno.

Os atributos espectrais e de texturas e o MDE foram amostrados pelas regiões das segmentações, por meio de um algoritmo desenvolvido em Python 2.7. Esse algoritmo extraiu os valores médios desses atributos para cada região da imagem segmentada. Para realizar essa rotina, foram utilizadas as bibliotecas GDAL, Numpy, OS e *Comma Separated Values* (CSV). A biblioteca CSV foi utilizada para ler e escrever arquivos no formato CSV, permitindo salvar os valores médios dos atributos das regiões. A rotina está representada no Apêndice B.

### 3.5.4 Atributos geométricos

Os atributos geométricos são originados da morfologia matemática. Essa área do conhecimento tem como propósito extrair características geométricas dos objetos. Dentre essas características, podem ser citados: a forma, a área e o contorno (Batista, 2006).

Alguns estudos têm obtido êxito na classificação de imagens utilizando atributos geométricos, como Silva et al. (2005), que utilizaram atributos geométricos para identificar padrões de desmatamento da Amazônia.

Fernandes et al. (2014), com objetivo de classificar junco gigante em ecossistemas ribeirinhos, identificou que os atributos geométricos extraídos da segmentação da imagem WorldView-2 foram os mais importantes na discriminação dessa classe.

Neste trabalho, foram selecionados os atributos geométricos descritos abaixo:

Área (area\_seg): É uma medida de quantidade de superfície, calculada sobre a região ou segmento (Equação 11).

$$\text{Área} = a \cdot \sum_{i=1}^n i \quad \text{Equação 11.}$$

em que  $a$  é a área de um pixel,  $n$  é o número de pixels de um segmento,  $i$  é a unidade de pixel.

Compactação (compact): Esse índice mensura o preenchimento de pixels em um retângulo inscrito no segmento (Equação 12). Também pode ser entendido como a concentração de pixels sobre um segmento. Valores próximos a um indicam que o segmento tem uma forma quadrada ou retangular.

$$\text{Compactação: } \frac{(l \cdot w)}{n} \quad \text{Equação 12.}$$

em que  $l$  é a comprimento em pixel,  $w$  é a largura em pixel e  $n$  é número de pixels da região.

Ajuste circular (ajus\_circ): Mede o desvio do segmento em relação a um círculo, o valor é mínimo para o segmento com forma igual a um círculo perfeito (Equação 13).

$$\text{Ajuste circular: } \frac{Ac_{fora}}{Ac_{dentro}} \quad \text{Equação 13.}$$

em que  $Ac_{fora}$  é a área do círculo que a região não está contida e a  $Ac_{dentro}$  é a área que a região está contida.

Ajuste retangular (ajus\_ret): Mede o desvio do segmento em relação a um retângulo (Equação 14). Valores próximos a zero indicam que o segmento tem uma forma quadrada ou retangular.

$$\text{Ajuste retangular: } \frac{Ar_{fora}}{Ar_{dentro}} \quad \text{Equação 14.}$$

em que  $Ar_{fora}$  é a área do retângulo que a região não está contida e a  $Ar_{dentro}$  é a área do retângulo que a região está contida.

Índice de forma (*ind\_form*): Esse índice indica a informação de suavidade e rugosidade dos contornos de um segmento, quanto menor seu valor, mais suave é o contorno (Equação 15).

$$\text{índice de forma: } \frac{bl}{4 \cdot \sqrt{A}} \quad \text{Equação 15.}$$

em que *bl* é o comprimento da borda em pixel e *A* é a área da região

Assimetria (*assim*): Essa medida indica a regularidade geométrica de um seguimento (Equação 16). Segmentos que se aproximam a uma circunferência e a um retângulo resultarão em valores menores.

$$\text{Assimetria} = 1 - \frac{l}{w} \quad \text{Equação 16.}$$

em que *l* é a comprimento e *w* é a largura

Para calcular esses atributos, foi desenvolvida uma rotina na linguagem Python 2.7 (Apêndice C), utilizando as bibliotecas de programação GDAL, Numpy, CSV, Math e *Scikit-image* (*skimage*), as duas últimas estão descritas abaixo:

**(a) Math:** É uma biblioteca que possui funções matemáticas.

**(b) skimage:** É uma coleção de algoritmos para processamento de imagens, a partir dele foi possível obter o número de pixels e o retângulo envolvente de cada segmento.

### 3.6 Seleção das regiões de treinamento

Um número suficiente de amostras de treinamento é geralmente necessário para realizar uma classificação bem sucedida. Essas amostras também devem ser bem distribuídas e suficientemente representativas em relação às classes de cobertura e uso da terra que estão sendo avaliadas (Lu e Weng, 2007).

Considerando isso, as amostras de treinamento para cada segmentação foram efetuadas utilizando pontos regulares. Esses pontos foram gerados com

distância de 25 metros entre eles, gerando um total de 1155 pontos de forma regular. sobre toda a área de estudo e compreendendo todas as classes de cobertura e uso da terra. A partir desses pontos, foram selecionados os segmentos de treinamento para cada limiar da segmentação. Construindo as amostras de treinamento dessa forma, não é preciso averiguar cada segmentação e selecionar as regiões que servirão como treinamento. Os 1155 pontos gerados para a área de estudo foram distribuídos para cada classe conforme a Tabela 4.

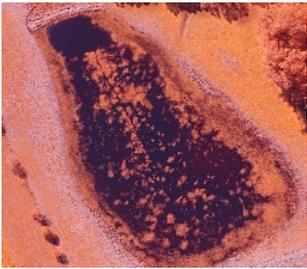
Tabela 4 - Classes de cobertura da terra e suas respectivas números de amostras.

Imagens	Classes	Descrição	Número de pontos de treinamento
	Mata nativa (MN)	Vegetação nativa da região.	54
	Silvicultura (SV)	Vegetação utilizada principalmente para produção de madeira.	19
	Sombra (SO)	Obstrução da radiação solar devido ao ângulo de iluminação.	38

---

	Pastagem (PA)	Vegetação rasteira para alimento de animais.	400
	Resteva (RE)	Local de onde se fez a colheita recentemente, sendo encontrados restos das plantas.	59
	Construção (CO)	Objetos construídos pelos homens.	4
	Solo exposto (SE)	Solo sem vegetação.	19
	Campo (CA)	Vegetação rasteira e nativa, utilizada no pastoreio de animais.	270
	Banhado (BA)	Área de baixadas mais úmidas	192

---

	Macrófita (MA)	Plantas aquáticas, que habitam desde brejos até ambientes aquáticos.	19
	Água/cinza (AC)	Corpo d'água com sedimento em suspensão.	5
	Água (AG)	Corpo d'água mais profundo e pouco sedimento em suspensão.	18
	Solo úmido (SU)	Solo exposto úmido.	58

### 3.7 Construção dos modelos por AD

Para construir os modelos por AD, foi utilizada a biblioteca de programação C5.0 disponível na linguagem R. O algoritmo original manteve-se comercial até 2011, quando Roy Quinlan disponibilizou o código fonte na linguagem C para comunidade científica. Posteriormente, Max Kuhn e sua equipe desenvolveram essa biblioteca para a linguagem R.

Foram testados os valores 0, 10, 20 e 30 para o parâmetro *trial*, quanto maior esse valor, mais iterações (ensaios) são realizadas. Também foi selecionado verdadeiro para a poda da árvore e inserido o valor dois para o número mínimo de instâncias.

Já a abordagem de seleção dos atributos é efetuada antes da construção da árvore. Os atributos são listados em ordem de importância, esse valor de importância é gerado avaliando o aumento do erro de classificação, quando o atributo é removido no momento da construção da árvore (árvore teste). No final a árvore é construída com os atributos mais informativos, como resultado também é obtido o valor de importância em porcentagem de cada atributo. O parâmetro *winnow* é controlado por valores booleanos, verdadeiro ou falso, para cada modelo gerado foram testados os dois valores.

No total foram gerados 40 modelos por AD, pois foram realizadas AD treinadas com os 5 valores de limiares de similaridade (1, 2, 5, 10, 15), em que cada uma foi avaliada com 4 diferentes valores para o parâmetro *trial* (0, 10, 20 e 30) e ainda foi considerado 2 valores para o parâmetro *winnow* (verdadeiro ou falso).

Esses modelos por AD foram construídos utilizando um código desenvolvido na Linguagem R (Quadro 1), para apoiar esse desenvolvimento são utilizadas as bibliotecas de programação C5.0 e Maptools. A primeira foi utilizada para criar o modelo por AD e a segunda para importar o arquivo *shapefile*, que continham os identificadores das regiões de treinamento.

Quadro 1 - Código de construção dos modelos por C5.0.

```

1#Impotar bibliotecas
library(C50)
library(maptools)
#Leitura do arquivo shapefile
shape = readShapePoints("shapefile_treinamento.shp")
#Leitura dos atributos em csv
textura = read.table('textura.csv', head=T)
espectral = read.table('espectral.csv',head=T)
geometrias= read.table('geometrias.csv',head=T)
#Selecionar os segmentos de treinamento
classes= factor(as.integer(shape$id_classes))
#Selecionar nos arquivos csv os identificadores das regiões
data.trein = data.frame(espectral[c(shape$seg),],geometrias[c(shape$seg),]2|
textura[c(shape$seg),])
#Criar modelo C50
model_tree = C5.0(data.trein,classes, trial = (0,10, 20,30),/
control=C5.0Control(winnow= (TRUE ou FALSE))
#Salvar o modelo em arquivo texto
out<-capture.output(summary(model_tree))
cat(out,file="ad_t0_wt.txt",sep="\n",append=TRUE)

```

<sup>1</sup> # Utilizado para comentar o código; <sup>2</sup> | Informa que o código continua.

### 3.8 Classificação das segmentações

De posse dos modelos, o próximo procedimento foi submetê-los à classificação das segmentações, para isso foi desenvolvido um algoritmo em Python 2.7 (Apêndice D), utilizando as bibliotecas GDAL e Numpy. O código faz leitura da imagem segmentada, utilizando a biblioteca GDAL. Também faz a leitura da AD gerada na Linguagem R e dos atributos espectrais, texturais e geométricos, que estão no formato CSV.

As imagens segmentadas possuem valores dos atributos para cada região, os arquivos com os atributos são conectados à imagem por uma coluna que contém a identificação dessas regiões. O processo inicia convertendo a AD em testes condicionais “*if else*”, e esses testes são aplicados na imagem segmentada, como resultado é obtido a classificação da segmentação.

### 3.9 Validação das classificações

As classificações foram avaliadas por meio de 500 pontos aleatórios independentes das amostras de treinamento, sendo distribuídas entre as classes conforme a Tabela 5.

Por meio dessas amostras de validação, foram geradas as matrizes de confusões para cada classificação de cobertura da terra. A matriz de confusão é formada pelo número de classes analisadas, possibilitando verificar visualmente os erros e os acertos das classificações para cada classe, os acertos entre as amostras de validação e a classificação ficam na diagonal da matriz, já os erros ficam fora dela. Além dessa primeira análise, a matriz de confusão possibilita derivar medidas e índices.

Tabela 5 - Amostras de validação distribuída entre as classes.

Classes	Número de pontos
Mata nativa (MN)	16
Silvicultura (SV)	9
Sombra (SO)	18
Pastagem (PA)	167
Resteva (RE)	31
Construção (CO)	3
Solo exposto (SE)	15
Campo (CA)	110
Banhado (BA)	94
Macrófita (MA)	8
Água/cinza (AC)	2
Água (AG)	8
Solo úmido (SU)	19

Neste trabalho, foram derivados: a exatidão global, a Acurácia do Usuário, a Acurácia do Produtor (AP) e o índice kappa. A exatidão global e o índice kappa foram calculados para todas as classificações, já a AU e AP foram calculadas somente para a classificação que resultou no maior índice kappa.

A exatidão global é calculada dividindo a soma da diagonal da matriz de confusão pelo total de amostras de validação, conforme ilustra a Equação 17.

$$G = \frac{\sum_{i=1}^c x_{ii}}{n} \quad \text{Equação 17.}$$

em que  $G$  é a exatidão global,  $x_{ii}$  é o valor da matriz diagonal,  $c$  é o número de classes e  $n$  é o número total de amostras de validação.

A Acurácia do Usuário (AU) pode ser entendida como a probabilidade de um pixel classificado na imagem representar a classe na qual foi indicado no campo. Essa medida é calculada sobre os erros de comissão, ou seja, amostras de validação classificadas erroneamente, que estão nas linhas da matriz de confusão. Seu cálculo está expresso na Equação 18.

$$AU = \frac{x_{+i}}{n} \quad \text{Equação 18.}$$

em que  $AU$  é a precisão do usuário e  $x_{+i}$  é a soma da linha  $i$ .

O cálculo da Acurácia do Produtor considera o erro de omissão, ou seja, as classes resultantes da classificação não foram as mesmas classes das amostras de validação. Essa medida também pode indicar a probabilidade de uma amostra de validação ser corretamente classificada. O seu cálculo está representado da Equação 19.

$$AP = \frac{x_{i+}}{n} \quad \text{Equação 19.}$$

em que  $AP$  é a precisão do produtor e  $x_{i+}$  é a soma da coluna  $i$ .

O índice kappa é uma técnica discreta multivariada utilizada na determinação da acurácia de mapas temáticos. Técnicas discretas nesses casos são apropriadas porque os resultados obtidos são classes discretas e não valores contínuos (Congalton, 2001). O cálculo do kappa considera a concordância real, dada pela exatidão global e a concordância por chance, expresso pelo produto total da linha e coluna, como está apresentado na Equação 20.

$$K = \frac{\theta_1 - \theta_2}{1 - \theta_2} \quad \text{Equação 20.}$$

em que

$$\theta_1 = \frac{\sum_{i=1}^c x_{ii}}{n} \quad \text{e} \quad \theta_2 = \frac{\sum_{i=1}^c x_{i+} x_{+i}}{n^2}$$

Para verificar se a diferença dos modelos gerados com *winnnow* igual falso ( $K_1$ ) em relação aos gerados com *winnnow* igual a verdadeiro ( $K_2$ ) são estatisticamente significantes, os valores dos índices kappa foram avaliados por meio do teste Z, conforme a Equação 21.

$$Z_{\text{calculado}} = \frac{K_1 - K_2}{\sqrt{\text{Var}(K_1) - \text{Var}(K_2)}} \quad \text{Equação 21.}$$

Como o Kappa é normalmente distribuído, sua variância pode ser calculada conforme a Equação 22 (Hudson e Ramm, 1987).

$$\text{Var}(K) = \frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2-\theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4-4\theta_2^2)}{(1-\theta_2)^4} \quad \text{Equação 22.}$$

sendo que,  $\theta_3$  e  $\theta_4$  são:

$$\theta_3 = \frac{\sum_{i=1}^c x_{ii}(x_{i+} + x_{+i})}{n^2}$$

$$\theta_4 = \frac{\sum_{i=1}^c \sum_{j=1}^c x_{ij}(x_{j+} + x_{+i})^2}{n^3}$$

em que  $X_{ij}$  é o valor da linha  $i$  e coluna  $j$  e  $X_{j+}$  é a soma da coluna  $j$ .

O valor  $Z$  obtido pela Equação 21 será comparado com  $Z$  tabelado, considerando um nível de significância de 5%, a área de aceitação da hipótese nula está compreendida no intervalo de -1,96 a 1,96. A hipótese nula ( $H_0$ ) e alternativa ( $H_1$ ) estão descritas abaixo.

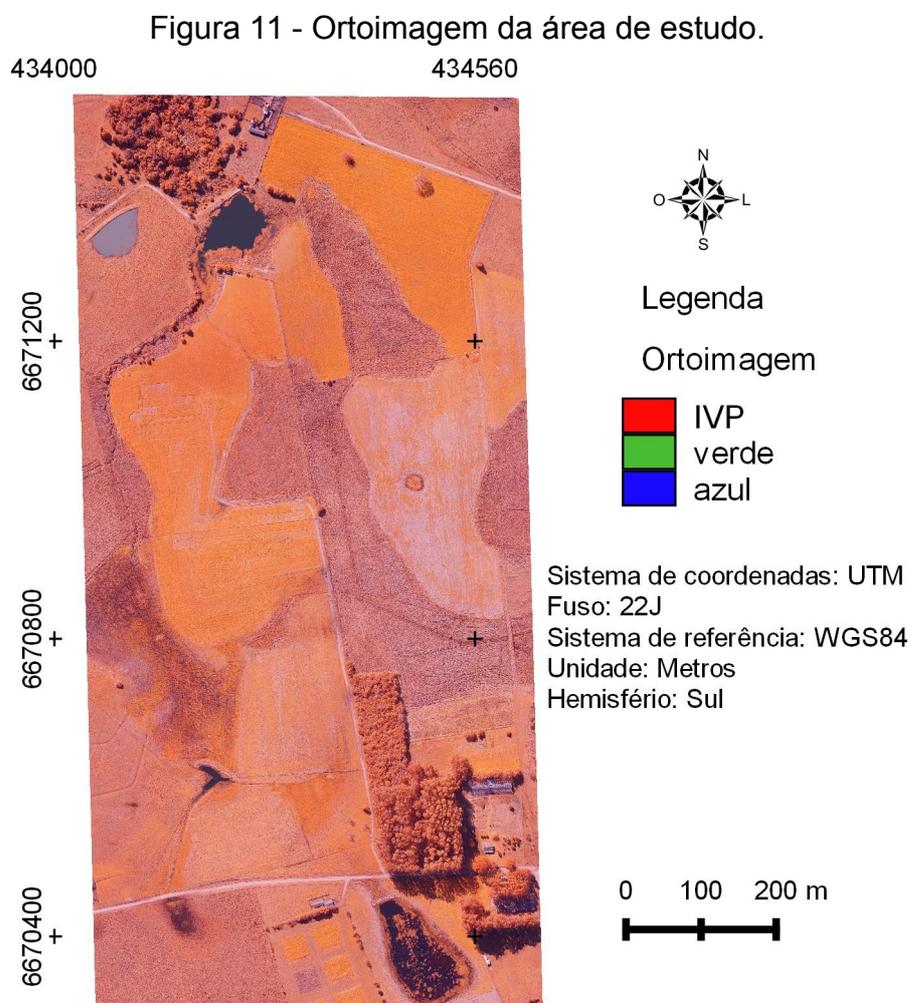
$H_0(K_1 - K_2) = 0$ , ou seja, considerando 5% de significância, os valores de índices kappa não são diferentes.

$H_1(K_1 - K_2) \neq 0$ , ou seja, considerando 5% de significância, os valores de índices kappa são diferentes.

Os cálculos de índice kappa, variância do kappa e acurácia global foram efetuados por meio de um código desenvolvido na linguagem Python 2.7 (Apêndice E), utilizando as bibliotecas GDAL, Numpy, OS, CSV e Statsmodels. O módulo Statsmodels possui funções estatísticas e, entre elas, o cálculo do kappa e de sua variância.

## 4 RESULTADOS E DISCUSSÕES

A ortoimagem abrangeu uma área total de 639,76 ha, com uma resolução espacial de 15 cm e uma precisão na georreferência de 1,54 m. Para este trabalho, foi utilizado um recorte de 73,15 ha (Figura 11), essa redução foi necessária para agilizar o tempo de processamento e as análises decorrentes. O recorte foi definido buscando concentrar as coberturas da terra presentes na ortoimagem original. Então, todos os processamentos foram executados no recorte da ortoimagem original, que, a partir daqui, será tratada como ortoimagem.



#### 4.1 Avaliação das segmentações

Ao realizar a segmentação das imagens, o número de regiões para os limiares de similaridade 1 e 50 foram de 696.778 e 38.077, respectivamente, com uma diferença no tempo de processamento de uma hora. Esse tempo máximo obtido no processamento pode ser entendido como satisfatório, porque são realizadas várias iterações sobre a imagem. A imagem original possui 8.234 linhas e 4.167 colunas, no total seriam 34.311.078 objetos de análises (pixels). Após a segmentação da imagem, o número de objetos reduziu-se para 696.778. Uma redução no número de objetos de análises pode facilitar o uso de grande conjunto de dados formado pelos atributos preditivos. A Tabela 6 representa o tempo de processamento e o número de regiões para os limiares analisados.

Tabela 6 - Tempo de processamento e número total de regiões

Limiar	Tempo (horas:minutos:segundos)	Número de regiões
1	01:14:19	696.778
2	01:10:34	688.503
5	01:03:25	630.417
10	00:43:07	433.488
15	00:30:23	283.679
20	00:23:04	185.432
30	00:16:15	92.466
40	00:11:23	56.857
50	00:10:12	38.077

Os algoritmos desenvolvidos para essa etapa do trabalho possibilitaram a avaliação das segmentações de forma automática, selecionando as imagens de uma pasta e aplicando o cálculo do RBSB sobre elas, sem a necessidade de convertê-las para arquivo vetorial.

Avaliando as segmentações em relação ao valor médio da área (Tabela 7), os limiares menores que 10 resultaram em uma área média de 1,3 m<sup>2</sup>, valores baixos podem representar um subsegmentação das regiões. Já os limiares de 15 a 50 variaram entre 2,72 m<sup>2</sup> e 20,27 m<sup>2</sup>. Ao verificar as segmentações pelo RBSB (Tabela 7), é entendido que os limiares menores que 15 geraram regiões relacionadas com

as geradas pelo especialista. Para os limiares maiores que 15, o valor para o RBSB foi alto, indicando que não foi encontrado correspondência entre as regiões de validação e as do segmentador. O melhor valor para o RBSB foi o encontrado no limiar 5.

Tabela 7 - Área média e RBSB.

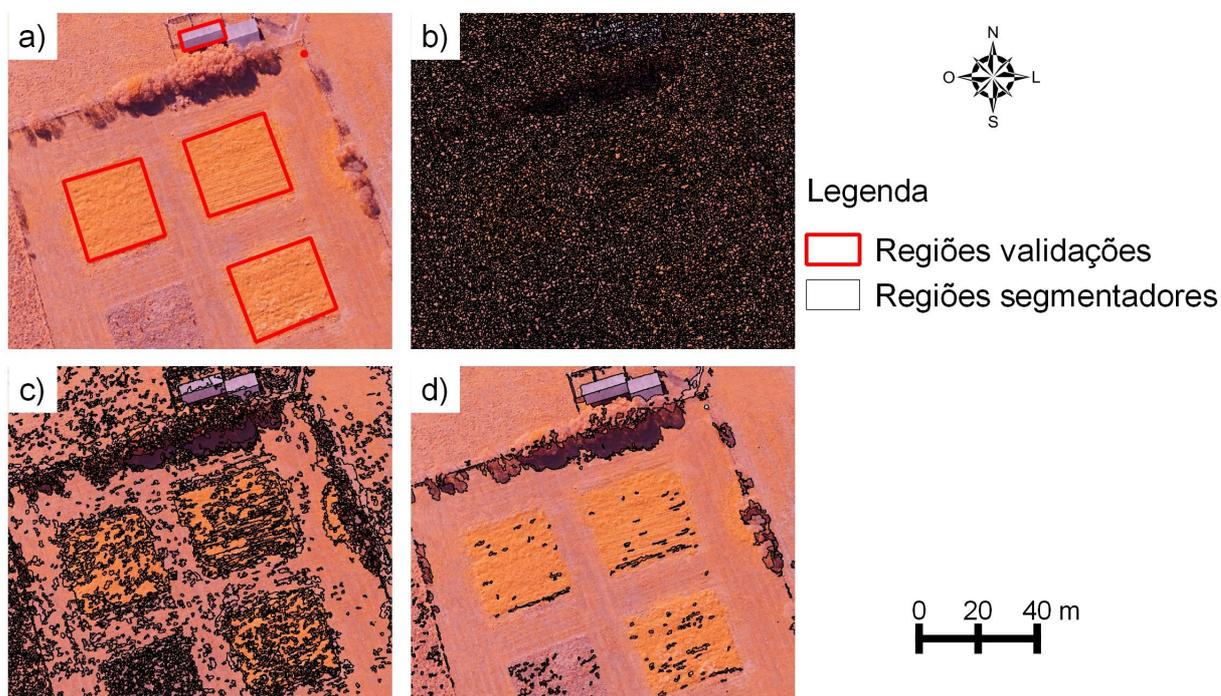
Limiar	Área média (m <sup>2</sup> )	RBSB
1	1,11	0,27
2	1,12	0,30
5	1,22	0,26
10	1,78	0,48
15	2,72	1,18
20	4,16	66,55
30	8,35	528,44
40	13,58	4.813,02
50	20,27	6.213,70

A partir da análise das regiões de validação, definidas pelo especialista, representadas na Figura 12a em vermelho, verifica-se que o limiar igual a 1 (Figura 12b) apresentou uma subsegmentação das regiões, apesar de resultar em valor para o RBSB de 0,27 (Tabela 7).

Diferentemente, para o limiar igual a 50 (Figura 12d), resultou em uma sobresegmentação das regiões como um alto valor para o RBSB (Tabela 7). Analisando, entretanto, em relação à classe sombra e à classe construção, esse valor de limiar obteve uma boa correspondência com as regiões de validação.

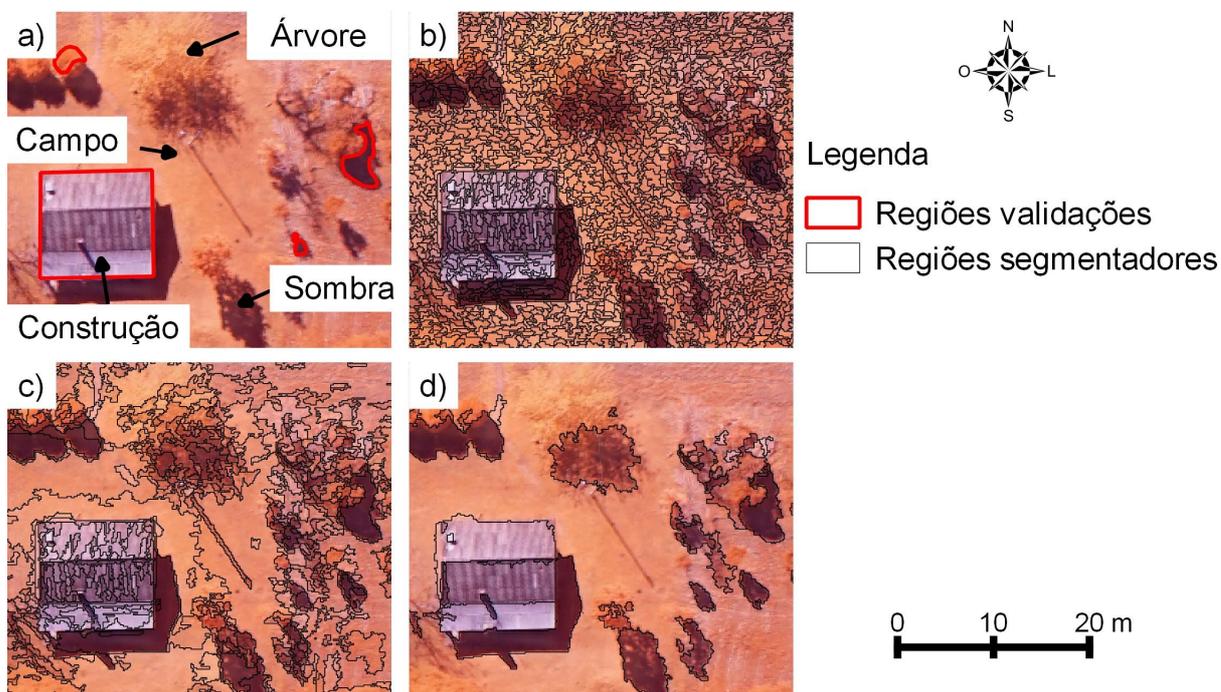
A Figura 12c representa a segmentação com limiar igual a 15, nesse caso, o segmentador conseguiu gerar regiões homogêneas que representam as classes de cobertura da terra. Na área de pastagem, por exemplo, essas regiões não foram unidas na classe campo, como aconteceu na segmentação com limiar 50.

Figura 12 - a) ortoimagem representada na escala 1:1600 e as regiões geradas pelo especialista, b) segmentação com limiar de similaridade 1, c) segmentação com limiar de similaridade 15 e d) segmentação com limiar de similaridade 50.



Avaliando as segmentações em uma escala maior (Figura 13a), constata-se que, para o limiar igual a 1, ocorreu o mesmo problema de subsegmentação das regiões (Figura 13b), também foi observado um sobresegmentação para o limiar igual a 50 (Figura 13d). Entretanto, ao avaliar as segmentações nessa escala em relação às coberturas da terra, verifica-se um subsegmentação das regiões na classe construção para o limiar igual a 15 (Figura 13c). Outro fato foi em relação à segmentação com limiar 50 (Figura 13d), em que as regiões geradas pela segmentação para as classes construção e sombra resultaram em uma alta correspondência com as regiões de validação. O problema dessa segmentação foi devido ao agrupamento das classes árvore (mata nativa) e campo em uma região.

Figura 13 - a) ortomagem representada na escala 1:800 e as regiões geradas pelo especialista, b) segmentação com limiar de similaridade 1, c) segmentação com limiar de similaridade 15 e d) segmentação com limiar de similaridade 50.



Ao considerar RBSB para avaliar as segmentações, constata-se que essa métrica corrobora para regiões menores que as de validação, como pode ser visto na Tabela 7 para os limiares 1 e 15. A segmentação com limiar 1 apresentou um subsegmentação das regiões, mas resultou em um valor de RBSB de 0,27. Já a segmentação com o limiar 15 resultou em um RBSB de 1,18. Avaliando as segmentações pelo RBSB, a melhor foi a com limiar igual a 5, mas visualmente a segmentação com limiar igual a 15 obteve uma melhor correspondência com as regiões delineadas pelo especialista.

A segmentação multirresolução disponível no Spring, que utiliza o método crescimento de regiões possibilitou delimitar os objetos da ortomagem. Cada valor de limiar apresentou maior correspondência em relação a alguma das classes de mapeamento, como o limiar igual a 50, que melhor definiu os limites das classes construção e sombra.

Dessa forma, entende-se que novos métodos de segmentação podem ser elaborados, considerando limiares em relação às classes, e não para a imagem como um todo. Isso melhoraria a delimitação das classes e consequentemente, facilitaria sua classificação.

## 4.2 Modelos por Árvore de Decisão (AD)

Os códigos criados para a construção dos modelos proporcionaram calcular os atributos geométricos das regiões, extrair os valores médios dos atributos para as regiões e criar os modelos por AD, sem a necessidade de converter as segmentações para arquivo vetorial e de forma automatizada.

Para as segmentações com valores de limiares 20, 30, 40 e 50, as construções dos modelos por AD foram descartadas, porque as regiões geradas por esses limiares continham mais que uma classe da cobertura da terra. Ou seja, no momento de selecionar as regiões utilizando os pontos regulares, essas regiões envolviam pontos de diferentes classes de cobertura da terra. Assim, não é possível determinar o conjunto de treinamento para todas as classes. Todos os modelos resultaram em tempo de processamento menor que 3 segundos.

A seleção das regiões de treinamento, por meio de pontos regulares, permitiu verificar se as regiões geradas pela segmentação representavam as classes de cobertura da terra, para as segmentações não representativas, não foi necessário investir tempo no processo de classificação. Como os pontos são regulares, o conjunto de dados de treinamento foi gerado proporcionalmente a ocorrência das classes na imagem. Classes maiores podem apresentar uma maior complexidade na classificação, assim um maior número de amostras para essa classe facilita sua separação das demais.

Para os outros limiares, foram gerados os modelos, como apresentados na Tabela 8. Avaliando essa tabela, verificou-se que, utilizando no mínimo o valor 10 para o parâmetro *trial*, foi possível obter um melhor ajuste do modelo em relação aos dados de treinamento, chegando a quase 100% em todos os modelos. Também verificou-se que ocorreu uma redução no tamanho da árvore, como pode ser visto no número de folhas.

Para o parâmetro *winnow*, não foi constatado qualquer padrão, observou-se que não houve diferença ao reduzir o número de atributos preditivos no ajuste do modelo ou no tamanho da árvore.

Tabela 8 - Taxas de acerto dos modelos em relação aos dados de treinamento e número de folhas.

Parâmetros		Limiaries									
		1		2		5		10		15	
<i>trial</i>	<i>winnow</i>	folhas	acertos (%)	folhas	acertos (%)	folhas	acertos (%)	folhas	acertos (%)	folhas	acertos (%)
0	<i>True</i>	139	91,3	146	92,5	134	91,8	115	91,9	115	91,9
0	<i>False</i>	140	92	140	92,4	155	94	142	94,1	107	92,9
10	<i>True</i>	125	99,9	126	100	126	100	124	99,8	117	98,8
10	<i>False</i>	127	100	125	100	131	100	116	99,9	105	98,8
20	<i>True</i>	120	100	134	100	115	100	122	99,9	97	98,9
20	<i>False</i>	130	100	126	100	132	100	118	99,9	101	99
30	<i>True</i>	127	100	125	100	121	100	117	99,9	101	99
30	<i>False</i>	120	100	127	100	129	100	123	99,9	97	99

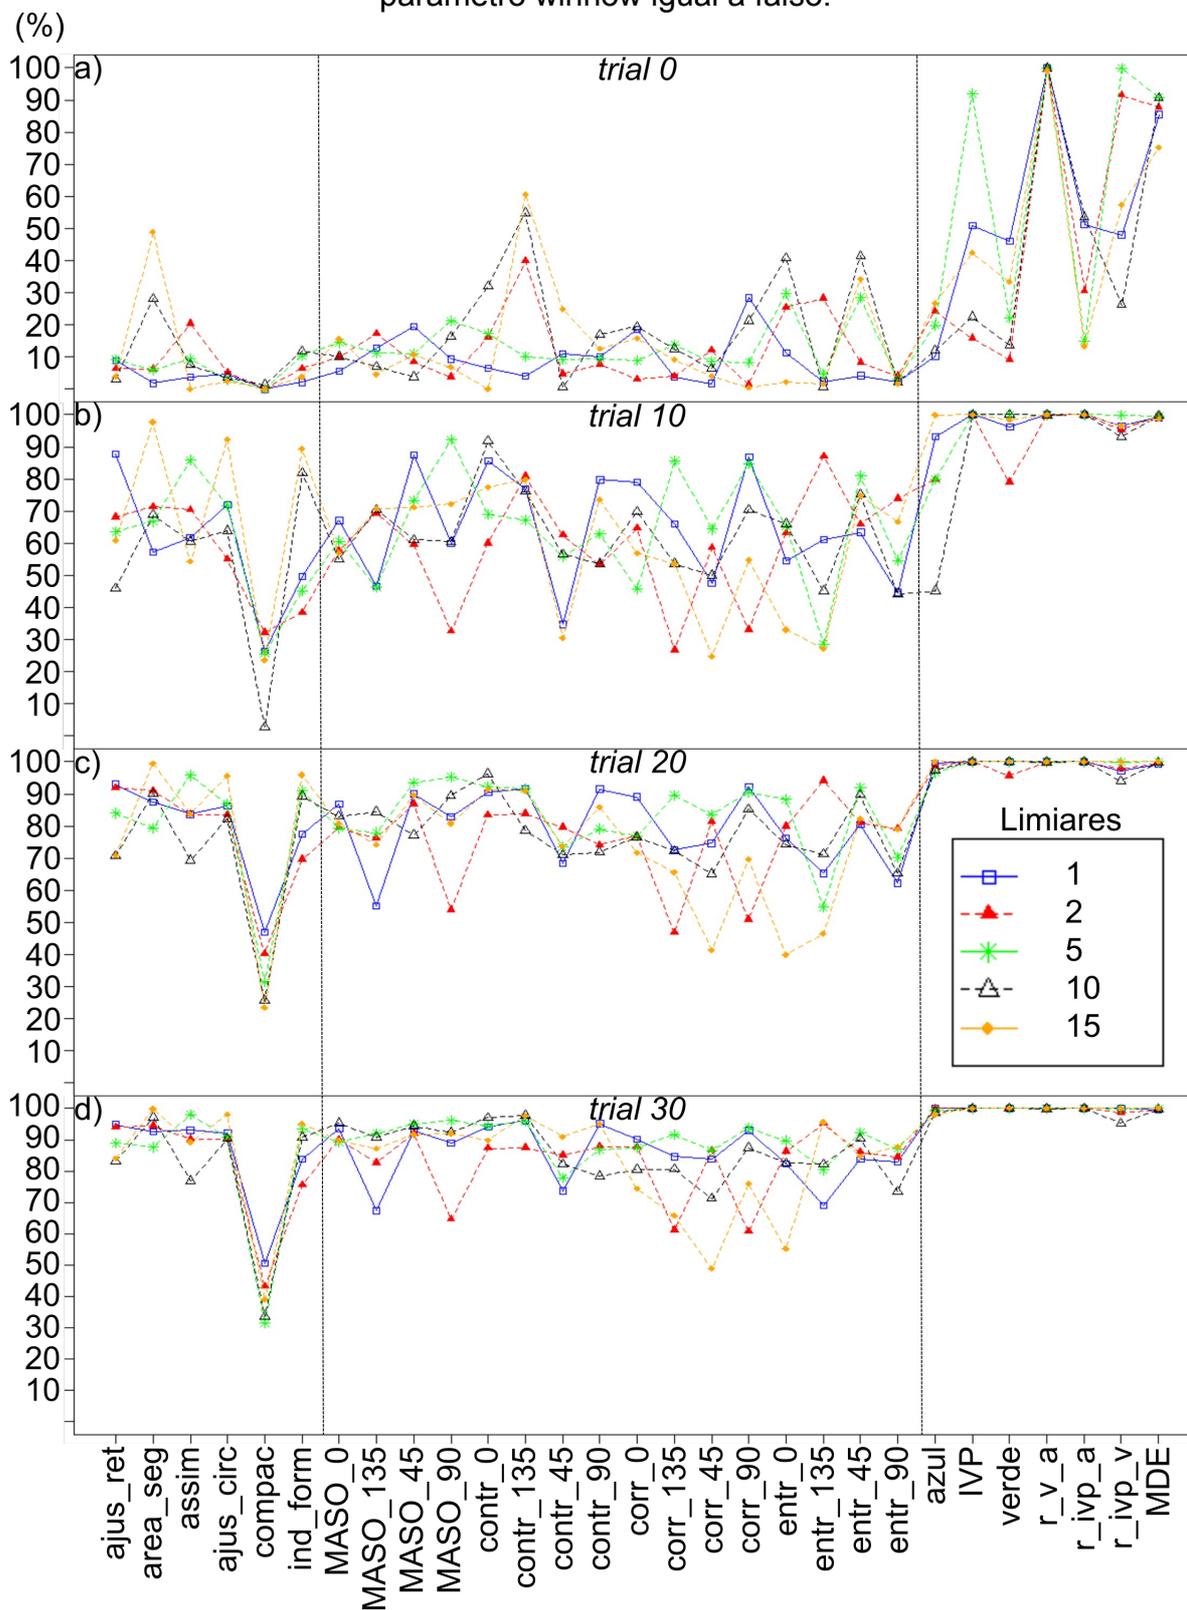
As taxas de uso dos valores de cada atributo preditivo, para os modelos por árvore que utilizaram *winnow* igual a falso, estão ilustradas na Figura 14. Essa taxa é calculada avaliando os valores dos atributos nos testes condicionais que estão nos nós da árvore. Os valores dos atributos preditivos após a discretização formam grupos com distintos intervalos de valores. Esses intervalos são obtidos considerando as classes e o parâmetro número mínimo de amostras. A partir desses grupos de valores, são realizadas as medidas de impureza e, dependendo do valor obtido, eles são utilizados nos testes condicionais da árvore. Por exemplo, uma amostra de dados de um atributo que, após a discretização gerou 20 grupos, resultaria no valor de uso 100%, caso todos os intervalos que representam os grupos fossem utilizados na árvore.

Para facilitar a interpretação, foram inseridas linhas verticais, na Figura 14, para separar atributos preditivos em: geométricos, texturais e espectrais, respectivamente. Os modelos gerados com reforço igual a zero (*trial* = 0) (Figura 14a) utilizaram basicamente os atributos *r\_v\_a* e o MDE.

Aumentando o número de ensaios para 10 (*trial* = 10) (Figura 14b), também aumentou o uso dos atributos geométricos e texturais. Isso ocorre porque o algoritmo avalia as taxas de erro de cada folha e faz novas buscas nos dados com intuito de diminuir essa taxa. Assim, os atributos que estavam sendo ignorados no

primeiro momento apresentam uma solução com menor erro e são utilizados na construção do modelo. Isso é percebido nas Figuras 14c e 14d, em que, aumentando os ensaios para 20 e 30, os valores estão se aproximando de 100%.

Figura 14 - Taxa de uso dos atributos na construção dos modelos para o parâmetro winnow igual a falso.



O atributo geométrico compactação (*compac*) foi o menos usado nas construções desses modelos, mostrando que é um atributo pouco representativo. Esse resultado é reforçado quando o índice de compactação é avaliado visualmente em relação às classes, uma vez que não é possível perceber qualquer padrão específico.

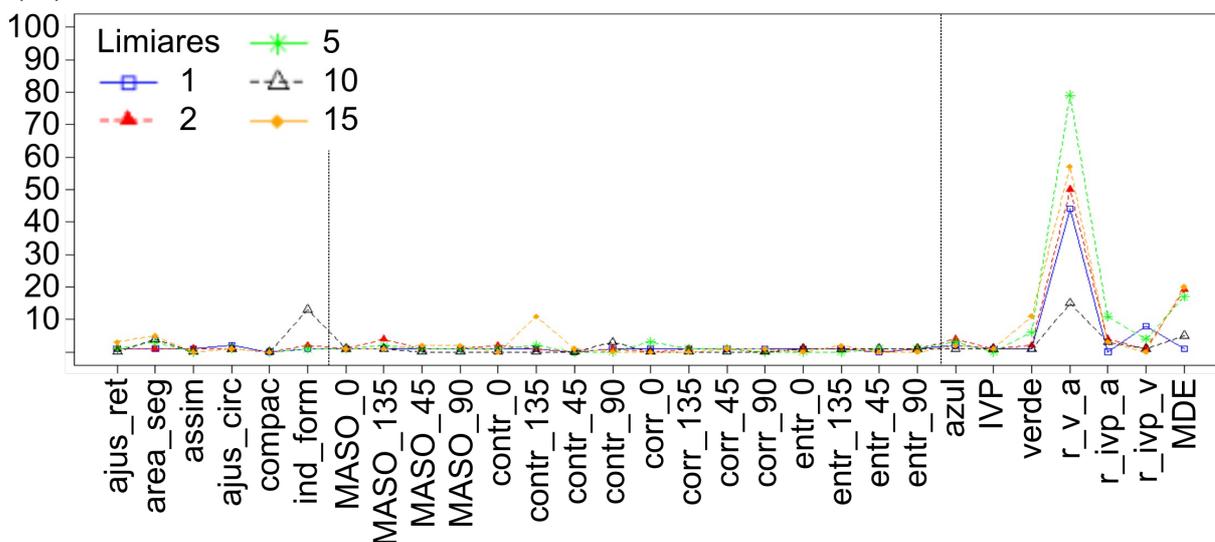
Examinando o número de folhas, a taxa de acerto (Tabela 8) e a taxa de uso dos valores dos atributos (Figura 14), são identificadas com o aumento de ensaios (*trial*) para *winnow* igual a falso, um melhor ajuste dos modelos aos dados de treinamento. Com isso, resultou-se em um menor número de folhas e maiores taxas de acertos (Tabela 8), além de considerar um número maior de atributos e utilizá-los mais seus valores na construção dos modelos (Figura 14).

O algoritmo C5.0 possibilita a seleção de atributos mais importantes (*winnow* = *True*) nas construções dos modelos, esse parâmetro estima a importância do atributo considerando o modelo de classificação gerado. Os valores de importância dos atributos para os modelos com ensaios iguais a 0,10, 20 e 30 e *winnow* igual à verdade resultaram na seleção dos mesmos atributos, também em valores de importâncias semelhantes. A explicação para isso é que o algoritmo constrói apenas um modelo e avalia a importância do atributo sobre ele, mesmo que seja informado um valor maior que zero para o parâmetro *trial*. Assim, não foi preciso gerar gráficos para todas as AD construídas com diferentes valores de ensaios.

Os valores de importância dos atributos sobre os modelos gerados para os dados de treinamento dos limiares de segmentação 1, 2, 5, 10 e 15, com valor 0 para o parâmetro *trial*, são representados na Figura 15. O atributo com maior importância foi o *r\_v\_a* para todos dados de treinamento, seguido do MDE. O índice de forma foi um atributo importante para AD treinada com dados do limiar igual a 10 e o contraste calculado com ângulo de 135 para o limiar igual a 15.

Vários atributos resultaram em uma importância menor que 1% e, devido à escala de representação do gráfico, a visualização desses valores é dificultada. O número de atributos com valor de importância maior que 1% para os limiares 1, 2, 5, 10 e 15 foram: 4, 8, 10, 12, 12, respectivamente. Isso significa que dos 29 atributos, os modelos gerados poderiam ser construídos com os atributos que estão inseridos nesses valores, sem perdas significativas no ajuste sobre os dados de treinamento.

Figura 15 - Importância dos atributos na construção dos modelos (*winnow = true*). (%)



Após o cálculo de importância dos atributos, a árvore é construída apenas com os atributos que apresentaram valores maiores que zero.

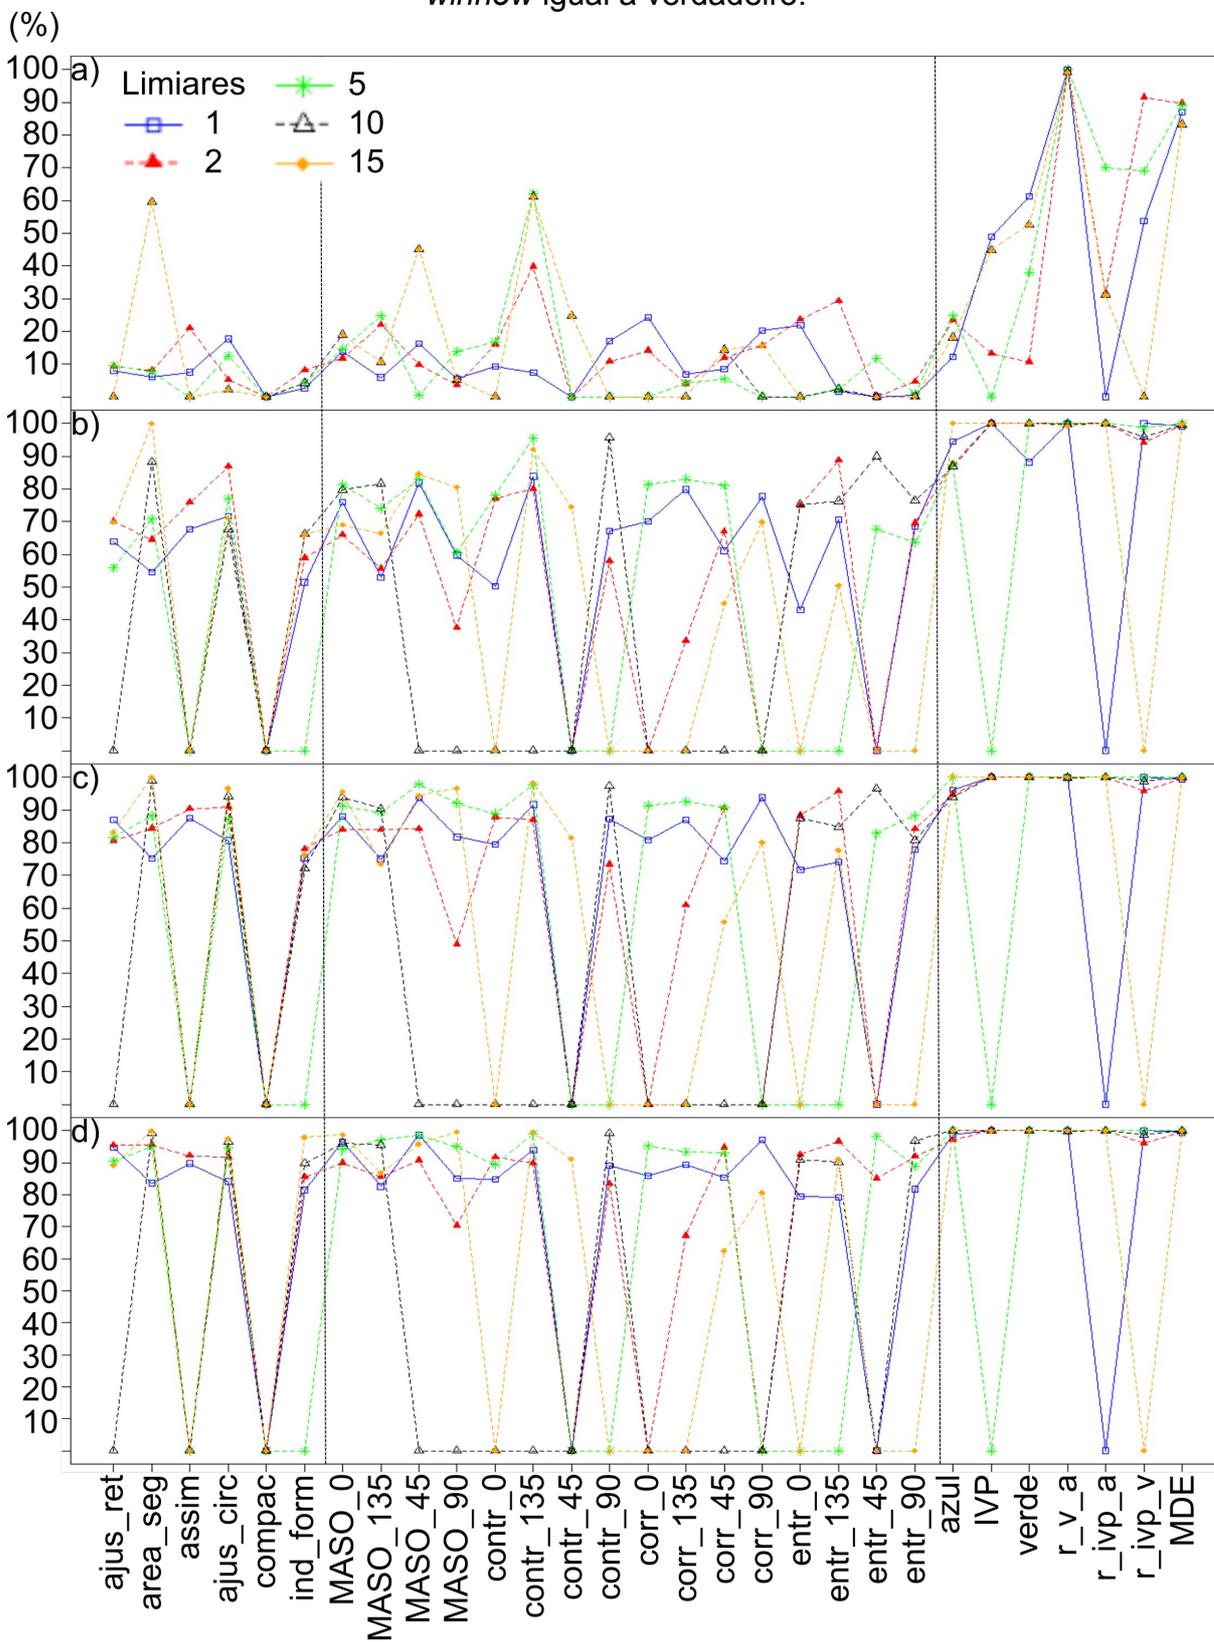
A Figura 16 apresenta a taxa de uso desses atributos na construção dos modelos. A Figura 16a exibe os valores de uso dos atributos para as AD construídas com o número de ensaios igual a zero. Os maiores valores foram encontrados para os atributos *r\_v\_a* e o MDE, seguido do contraste calculado para um ângulo de 135° (*contr\_135*). Com o aumento do número de ensaios para o valor 10 (Figura 16b), outros atributos foram utilizados, como é caso dos atributos *area\_seg*, *ajust\_circ*, *MASO\_0*, *MASO\_135*, *azul* e *verde*. O atributo *contr\_135* foi desconsiderado para a AD treinada com os dados do limiar igual a 10.

Avaliando a Figura 16c e a Figura 16d, não é possível perceber um padrão de uso dos atributos na construção dos modelos, apenas oito atributos supracitados foram considerados em todos os modelos. Isso pode ter acontecido porque as segmentações dadas pelos limiares geram regiões totalmente diferentes, mesmo que fosse utilizado o mesmo limiar de similaridade na segmentação, as regiões geradas seriam distintas, porque os pixels sementes são gerados aleatoriamente. Devido a isso, os cálculos médios para os valores espectrais e de texturas, assim como para os valores geométricos que formam as amostras de treinamento, são muito distintos.

Os atributos *r\_v\_a* e o MDE apresentaram os maiores valores de importância e foram os mais utilizados nas construções dos modelos. Isso quer dizer, portanto, que foram os atributos que melhor separaram as classes de cobertura da terra. A

hipótese era que a banda do IVP seria uma das mais importantes devido ao número de classes de vegetação que estão sendo consideradas.

Figura 16 - Taxa de uso dos atributos na construção dos modelos para o parâmetro *winnow* igual a verdadeiro.



Avaliando visualmente o MDE é identificado que a classe silvicultura representa a parte mais alta, em um outro patamar está a classe mata nativa, com árvores de menor porte em relação as de silvicultura. Também é identificado locais mais alto no relevo para as classes pastagem e campo. Esse comportamento altimétrico das classes pode ter sido o motivo, desse atributo ser um dos mais importantes na discriminação das classes de cobertura da terra deste estudo.

O atributo  $r\_v\_a$  também foi inserido como raiz em todos os modelos, com isso pode-se considerá-lo com menor valor de impureza, ou seja, o atributo mais significativo para separação das classes.

Lalibert et al. (2011b), avaliando atributos espectrais obtidos da imagem com bandas do visível, utilizando o algoritmo CART para seleção dos atributos, obtiveram como atributo mais importante a razão entre as bandas do vermelho e do verde. Dentre os 22 atributos do conjunto de dados, foram selecionados apenas 10, sendo que os 3 atributos geométricos dos conjuntos de dados foram selecionados. Os atributos geométricos foram escolhidos porque algumas classes de cobertura da terra apresentavam formas específicas e podiam ser diferenciadas pela área.

No presente estudo, os atributos espectrais também foram os mais importantes, mas, dentre os atributos geométricos, apenas dois deles foram considerados em todos os modelos (Figura 16), entre eles a área do segmento ( $area\_seg$ ). Fernandes et al. (2014) também identificaram a área do segmento como atributo importante, mas nesse trabalho, o objeto foi identificar a espécie junco gigante.

Em outro estudo realizado por Laliberte e Rango (2009), foram avaliados os atributos de textura na classificação de classes de pastagens. Os autores observaram que os atributos de texturas melhoram a acurácia das classificações em quase todos os casos, dando ênfase à medida da entropia, porque essa textura obteve os maiores valores de importância nos modelos por AD gerados.

Sintetizando os principais resultados em relação ao uso da AD, pode-se relatar que o algoritmo C5.0, utilizando valores maiores que zero para o parâmetro *trial*, melhora o ajuste do modelo em relação aos dados de treinamento. Também verificou-se a importância dos atributos espectrais e do atributo MDE nas construções dos modelos.

### 4.3 Classificações

Para realizar a etapa de classificação foi necessário desenvolver rotinas de programação, que transformou as AD obtidas pelo código gerado na linguagem R em testes condicionais, posteriormente. Esses testes condicionais foram, posteriormente, aplicados no conjunto de dados das regiões, gerando as classificações da cobertura da terra para cada modelo por AD.

Com esses códigos, todas as classificações foram realizadas de forma automática, não necessitando convertê-las para o formato vetorial. Apenas foi necessário executar esses algoritmos para cada modelo, porque foi preciso informar a pasta de cada modelo e o respectivo conjunto de dados. O cálculo do kappa e de sua variância também foram realizados para todas as classificações sem a necessidade de conversão e de forma automatizada.

O processo de classificação apresentou um tempo de processamento para cada imagem de aproximadamente 24 horas, o que pode estar relacionado com a linguagem utilizada. Linguagens interpretadas de modo geral, como é o caso do Python, apresentam processamento inferior às linguagens compiladas.

Os valores do índice kappa para as classificações da cobertura da terra, Figura 16, quando o parâmetro de seleção dos atributos foi marcado como falso (*winnow = false*) (Figura 17a), apresentaram um resultado de 0,71 para o melhor caso e uma acurácia global de 77%. Esses valores foram encontrados para o modelo construído com amostras do limiar igual a 15 e *trial* igual a 0.

Para a opção verdadeiro do parâmetro *winnow* (*winnow = true*) (Figura 17b), os melhores resultados também foram encontrados para o limiar igual a 15 e *trial* igual a 0, obtendo um índice kappa de 0,69 e uma acurácia global de 75%. As amostras de treinamento obtidas por meio do limiar igual a 15 resultaram em quase todos os casos nos melhores índices kappa. Apenas houve uma semelhança nos valores do kappa quando o parâmetro *winnow* foi verdadeiro e *trial* igual a 10 (Figura 17b).

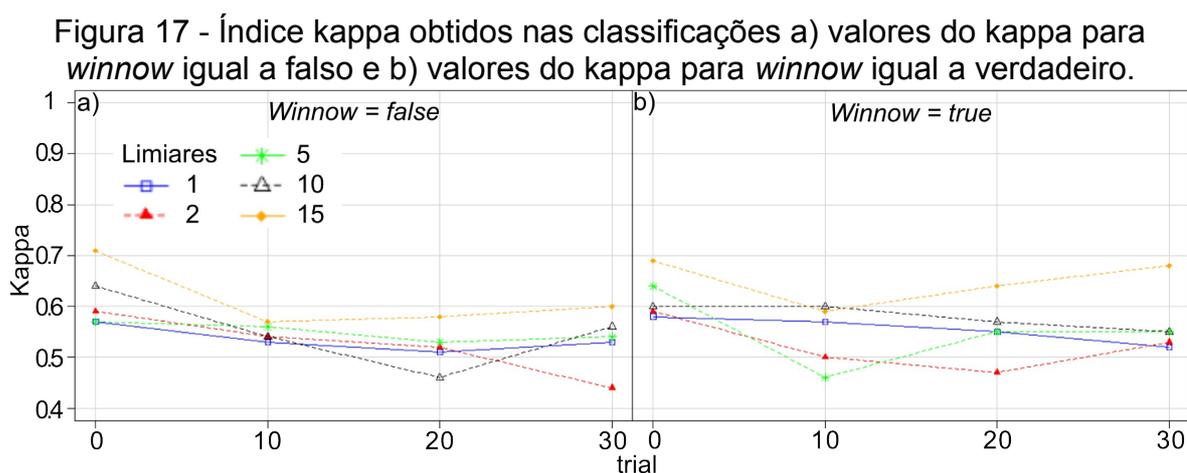
O pior caso foi encontrado no modelo treinado com amostras do limiar igual a 2, *trial* igual a 30 e *winnow* igual a falso (Figura 17a), resultando em um índice kappa de 0,44 e acurácia global de 56%.

Ao avaliar os valores do RBSB para os limiares de similaridades 1, 2, 5, 10 e

15, o valor mais alto foi obtido pelo limiar igual a 15, que resultou em um valor de 1,18. Sabendo que valores ótimos para o RBSB são próximos a zero, pode ser entendido que essa medida não seja suficiente para a escolha do melhor limiar de similaridade a ser utilizado na segmentação, porque o melhor valor de índice kappa foi encontrado para o limiar igual a 15.

Considerando o número de reforços (*trial*) utilizados na construção dos modelos, os limiares apresentaram maiores valores de índice kappa para o valor igual a 0 (*trial* = 0), ou seja, mesmo quando o parâmetro *winnow* foi selecionado igual a falso ou igual a verdadeiro, os modelos com *trial* igual a 30 resultaram em menores valores em relação a *trial* igual a 0. Isso pode ter acontecido porque o algoritmo considera a taxa de erro da folha sobre os dados de treinamento, com isso o modelo consegue se ajustar perfeitamente aos dados de treinamento.

Oberserva-se na Tabela 8, que as taxas de acertos dos modelos para *trial* igual a 0 e *winnow* igual a falso ou verdadeiro são de aproximadamente 92%. Ao modificar o valor do parâmetro *trial* para 10, os modelos gerados já se ajustam aos dados de treinamento a uma taxa de 100%, perdendo o poder de generalização. Ao considerar *trial* igual a 0, não são feitas novas tentativas de se ajustar aos dados de treinamento, possibilitando que o modelo generalize mais, resultando em melhores classificações sobre dados não conhecidos.



A partir da Figura 18, é possível avaliar os resultados obtidos pelo parâmetro *winnow*, com a diferença dos índices kappa dos modelos com o mesmo valor de limiar e *trial*. Os modelos gerados com o limiar igual a 1 e *trial* igual a 0, com *winnow* igual a falso e verdadeiro, por exemplo, apresentaram os valores de índice kappa

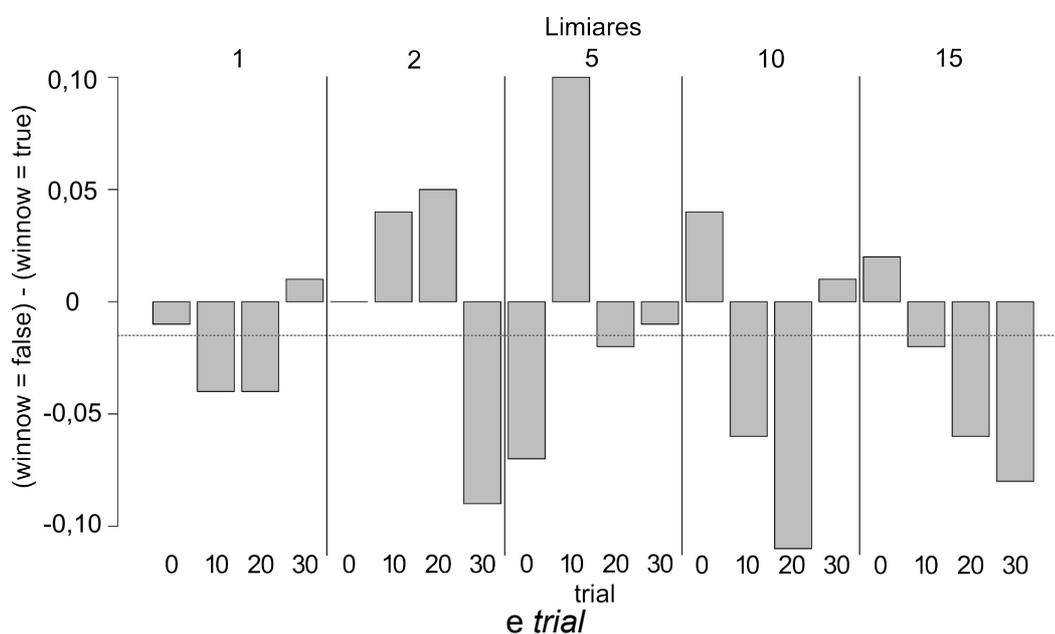
0,57 (Figura 17a) e 0,58 (Figura 17b), respectivamente. A diferença entre esses modelos foi de -0,01. Esse valor está expresso na primeira barra da Figura 18. O eixo vertical da Figura 18 representa a diferença dos modelos gerados com as opções falsa e verdadeira para o parâmetro *winnow*. Os valores negativos indicam que, ao escolher verdadeiro para o parâmetro *winnow*, foi obtido um valor de índice kappa maior.

A linha horizontal tracejada representa a média dessas diferenças, já as linhas verticais dividem os valores de limiares utilizados. O valor encontrado para a média foi de -0,017, indicando que, quando foi selecionado verdadeiro para o parâmetro *winnow*, ocorreu uma pequena melhora nos valores de índice kappa.

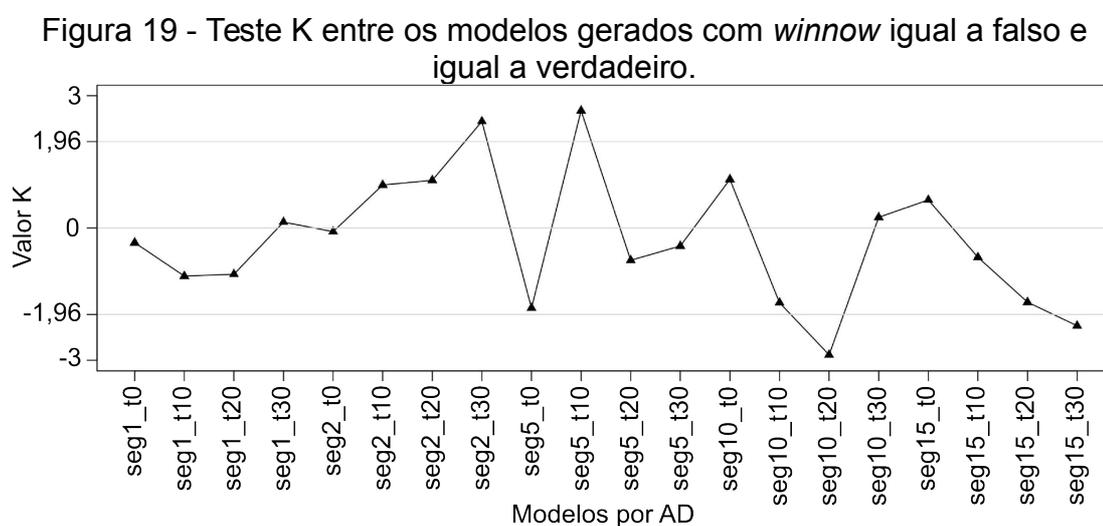
Essa correspondência é confirmada ao analisar os 20 valores de diferenças. Dado que 12 apresentaram maiores valores quando foi utilizado verdadeiro para o parâmetro *winnow*, 1 resultou no mesmo valor de kappa (limiar igual 2 e trial igual a 0) e 7 resultaram em maiores valores quando foi selecionado falso para o parâmetro *winnow*. Desses 7 valores, 5 ficaram maiores que -0,05, ou seja, convertendo para positivo esses valores, eles não se diferenciaram mais que 0,05 em relação aos seus valores de índice kappa.

A maior diferença para os índices kappa foi para o limiar igual a 10 e *trial* igual a 20, obtendo um valor de -0,11. Nesse caso, ao selecionar verdadeiro para o *winnow*, o modelo foi gerado com 19 dos 29 atributos preditivos, melhorando o índice kappa de 0,46 para 0,57.

Figura 18 - Diferença dos índices kappa para os mesmos valores limiares



Com o intuito de avaliar se essas diferenças são estatisticamente significativas, foram calculados os valores do teste Z para os índices kappa (Equação 21). Os resultados do teste Z estão representados na Figura 19. As linhas horizontais representam a área de aceitação da hipótese nula, as quais compreendem o intervalo de -1,96 a 1,96. Os valores do teste Z que estão dentro dessa área são considerados iguais. Isso quer dizer que se aceita a hipótese nula para esses valores, ou seja, para uma significância de 5%, esses valores não são diferentes.



Já para os valores que se apresentam fora desse intervalo, rejeita-se a hipótese nula e aceita-se a hipótese alternativa. Com isso, os valores de índice kappa obtidos por esses modelos são considerados diferentes. Dentre os 20 modelos comparados, apenas 4 podem ser considerados diferentes, podendo-se concluir que, neste estudo, ao selecionar a opção verdadeira para o parâmetro *winnow*, não houve melhora na classificação da cobertura da terra.

Um ganho, ao considerar a seleção de atributos mais importantes (*winnow = true*) no momento da construção do modelo é em relação à redução dos atributos preditivos. Essa redução, na maioria dos casos é feita sem a perda da acurácia, como ilustra a Figura 18. Como pode ser visto no modelo gerado com limiar igual a 15, trial a 20 e *winnow* igual a verdadeiro, a redução de 10 atributos preditivos sem diminuir o valor do kappa.

Essa redução significativa no número de atributos preditores, facilita trabalhos que utilizam OBIA, porque remove dados correlacionados e reduz a

dimensionalidade do conjunto de dados. Esses benefícios da redução do número de atributos preditores são vistos nos trabalhos de Laliberte et al.(2011c). Esses autores aplicam essa redução e, posteriormente, com os atributos mais importantes, classificam as regiões utilizando o classificador vizinho mais próximo. Hellesen e Matikainen (2013) utilizaram AD criada sobre os atributos mais importantes, para classificar pequenos arbustos e árvores em uma imagem multispectral obtida por VANT.

Para melhor entender as confusões entre as classes, foi avaliada a classificação com o melhor valor de índice kappa. Nesse contexto, foi o modelo treinado com as amostras do limiar igual a 15, *trial* igual a 0 e *winnow* igual a falso, resultando em um índice kappa de 0,71. De acordo com Landis e Koch (1977), uma classificação com esse valor de kappa pode ser considerada muito boa.

Os atributos mais usados nesse modelo foram a *r\_g\_b* (99,1%), *MDE* (75,3%), *contr\_135* (60,7%), *r\_iv\_g* (57,3%), *area\_seg* (48,8%), *IVP* (42,5%), *entr\_45* (34,1%), *verde* (33,4%), *azul* (26,7%), *contr\_45* (24,7%) e outros com taxas de uso menores que 20% (Figura 14a).

Considerando os atributos preditivos mais usados nessa árvore, foi identificado que as bandas da imagem, as razões entre as bandas do verde com azul e verde com IVP, juntamente com MDE, foram os mais importantes na discriminação das classes. O atributo geométrico mais usado foi apenas a área dos segmentos (*area\_seg*), mostrando, nesse caso, que os atributos geométricos não apresentaram padrões que possibilitassem diferenciar as classes.

Hamedianfar e Shafri (2014) ao classificar uma imagem WorldView-2 de uma área urbana, combinando OBIA e árvore de decisão, obtiveram como o atributo raiz da árvore o índice espectral da diferença normalizada da borda do vermelho e verde. Os comprimentos de onda da borda do vermelho e do verde para o sensor WorldView-2 são, respectivamente, 705–745 nm e 630–690 nm.

Destaca-se que a banda da IVP utilizada no presente estudo captura dados no intervalo de 670 a 770 nm, o que incorpora quase as duas bandas e mais uma parte da banda do infravermelho próximo do sensor WorldView-2. Essa banda mais larga dificulta a discriminação de alvos com resposta espectral muito próximas, como é o caso das classes de cobertura vegetal.

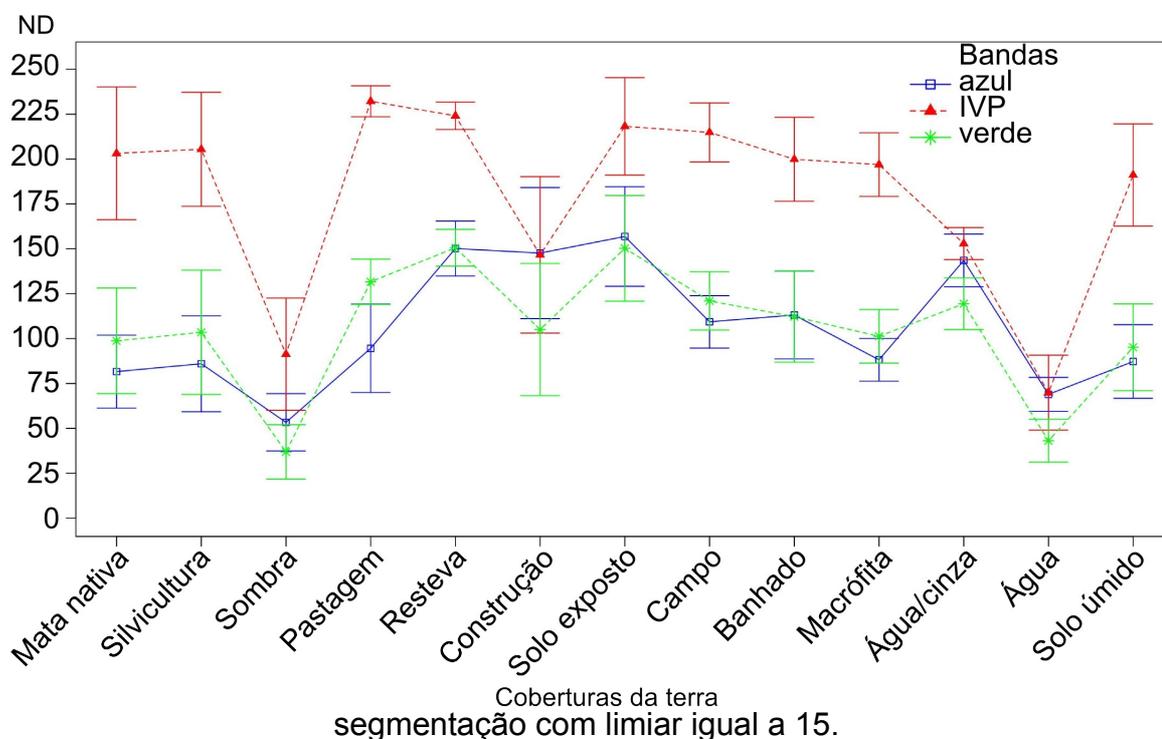
O intervalo de comprimento de onda da banda do IVP utilizada neste trabalho compreende um longo intervalo (670 nm – 770 nm), sendo sensível a diferentes

respostas espectrais. Com isso pode estar saturando as respostas espectrais dos alvos, como pode ser visto na Figura 20.

Os valores médios e o desvio padrão das amostras de treinamento da segmentação com limiar igual a 15, divididos por classes, estão apresentados na Figura 20. Para a banda do IVP, as classes de vegetação apresentam valores altos e próximos, como a mata nativa, silvicultura, campo, banhado e macrófita. Essas classes concentram seus valores de ND aproximadamente entre 200 a 225, nesse mesmo intervalo estão os valores das classes resteva e solo exposto.

Torres-Sánchez et al. (2013), com objetivo de discriminar ervas daninhas na agricultura, utilizaram uma câmara Tetracam mini-MCA-6 acoplada a um hexacoptero. Essa câmara possui 6 filtros, que variam 10 nm do comprimento de onda central: azul (450 nm), verde (530 nm), vermelho (670 e 700 nm), borda do vermelho (740 nm) e IVP (780 nm). Os autores observaram que a maior separabilidade entre vegetação e solo exposto foi dada por meio do NDVI.

Figura 20 - Valores médios e o desvio padrão dos dados de treinamento da



Como visto nos trabalhos supracitados, a banda do vermelho, a borda do vermelho e a IVP foram as mais importantes na separação das classes. Nesses trabalhos, essas bandas compreenderam pequenos intervalos de comprimentos de

onda. Ao contrário do presente trabalho, em que a banda do IVP possui um largo intervalo, isso diminui o contraste entre os alvos. Essa diminuição no contraste é possivelmente o motivo dessa banda não ser a mais importante na discriminação das classes de cobertura da terra deste estudo.

A Tabela 9 representa a matriz de confusão para essa classificação. Também foi inserido nessa tabela o número de folhas encontrado para cada classe. Uma forma de avaliar as confusões entre classes geradas pelo modelo de classificação é o valor da AP. Essa medida indica a probabilidade de acerto da classificação sobre os dados de validação. Considerando isso, os menores valores de acerto foram encontrados para as classes mata nativa (MN), construção (CO) e macrófita (MA), que resultaram nos valores 31,3%, 33,% e 12,5%, respectivamente.

Tabela 9 - Matriz de confusão do limiar igual a 15, *trial* igual a 0 e *winnow* igual a falso.

		Classificação													$x_{i+}$
		MN	SV	SO	PA	RE	CO	SE	CA	BA	MA	AC	AG	SU	
Verdade Terreno	MN	5	1	3	6	0	0	0	1	5	0	0	0	0	21
	SV	1	7	0	0	0	0	0	0	0	0	0	0	0	8
	SO	0	0	14	0	0	1	0	0	2	1	0	2	0	20
	PA	4	0	0	134	5	0	1	14	3	0	0	0	0	161
	RE	0	0	0	3	19	1	3	4	3	0	0	0	0	33
	CO	0	0	0	0	0	1	0	0	0	0	0	0	0	1
	SE	0	0	0	0	4	0	10	1	1	0	0	0	0	16
	CA	3	0	0	14	2	0	1	75	8	2	0	0	1	106
	BA	1	0	0	0	1	0	0	10	65	0	0	0	3	80
	MA	1	0	0	1	0	0	0	1	0	1	0	0	0	4
	AC	0	0	0	0	0	0	0	0	0	0	2	0	0	2
	AG	0	0	0	0	0	0	0	0	0	0	0	6	0	6
	SU	1	1	1	9	0	0	0	4	7	4	0	0	15	42
	$x_{+i}$	16	9	18	167	31	3	15	110	94	8	2	8	19	
AP (%)	31,3	77,8	77,8	80,2	61,3	33,3	67	68	69	12,5	100	75	79		
folhas	16	3	6	18	9	1	4	22	13	3	2	2	8		

As duas maiores confusões da classe MN ocorrem entre as classes pastagem (PA) e campo (CA). A confusão entre MN e PA pode ser explicada pela superestimação do modelo para a classe PA, já que para essa classe foram coletadas 400 amostras de treinamento (Tabela 4). Algumas dessas amostras podem ter sido coletadas sobre locais da pastagem com menor vigor vegetativo, fazendo com que o modelo gerasse regras de decisão que englobassem outras classes próximas daquela resposta.

Um atributo que poderia diferenciar a classe MN da CA seria o MDE. Na ortoimagem a classe MN está localizada em duas áreas principais, uma ao norte, com árvores de maior porte, e outra mais ao sul, com árvores menores e mais densas. As amostras de treinamento coletadas sobre essa segunda área podem ter sido o motivo de o modelo usar menos o atributo MDE para discriminar a classe MN, porque as amostras da segunda área possuem textura e radiância semelhante ao CA.

A classe construção (CO) foi confundida com as classes sombra (SO) e resteva (RE). Em alguns locais das construções, são encontradas na ortoimagem áreas com sombras tênues. Então, no momento de determinar a classe da amostra de referência sobre esse local, pode ter sido determinado como construção e não como sombra. Outro motivo dessa confusão pode ter sido devido ao número de amostras utilizadas para treinar essa classe, já que foram utilizadas apenas 4 amostras. A partir dessas amostras, o modelo gerou apenas uma regra na árvore para discriminar essa classe. Tal regra de classificação está ilustrada no Quadro 2.

Quadro 2 - Regra de classificação para a classe construção.

Se ( $r_{g\_b} \leq 1,163$ , se ( $contr_{135} > 8,298$ , se ( $r_{iv\_g} \leq 1,624$ , se ( $azul \leq 129,796$ , se ( $ASM_{45} > 0,133$ , então, classe = construção, caso contrário, classe = outras)))))).
---

Avaliando essa regra, fica evidente o uso da maior parte de atributos espectrais e texturais, dificultando a classificação porque as classes resteva e sombra são muito próximas espectralmente com a classe construção. Também não é percebido visualmente nenhum padrão de texturas nessas classes. Os atributos geométricos são mais bem sucedidos em classificações com classes urbanas, como é caso da construção, mas isso não foi detectado pelo modelo.

Essa falha do modelo pode estar relacionada com amostragem utilizada, porque o segmentador com limiar igual a 15 gerou pequenas regiões sobre a classe construção (Figura 12c), assim os atributos geométricos para essas regiões, não apresentam padrões específicos em relação à classe. Ao contrário da segmentação com limiar igual a 50 (Figura 12d), em que as regiões formadas possuem uma forma retangular.

A classe macrófita (MA) foi a que resultou em um menor AP, apenas 12,5%, ou seja, das 8 amostras de validação, apenas uma foi classificada corretamente. Essa classe pode ser considerada uma das mais complexas de serem discriminadas. Ela está presente somente nos corpos d'água e, mesmo assim, possui uma alta variabilidade espectral, apresentando vegetação com alto vigor e vegetação com menor vigor ao se afastar do centro dos corpos d'água. Essa vegetação menos vigorosa, associada ao ambiente úmido, foi confundida com a classe solo úmido (SU), já que, das 8 amostras, 50% foram classificadas como SU. As demais classes apresentaram um acerto de mais de 60%, em alguns casos, como na classe água cinza (AC), resultou em um acerto de 100%.

Avaliando o número de folhas em relação ao valor AP, não foi encontrada nenhuma correspondência, ou seja, o número de folhas não está relacionado com a acurácia de classificação do modelo. No entanto, esse número de folhas está diretamente relacionado com o número de amostras (Tabela 4) e com a complexidade de separação da classe.

Na Figura 21 estão representados os recortes da ortoimagem e a sua respectiva classificação, resultado do modelo treinado com limiar igual a 15, *window* igual a falso e *trial* igual a 0.

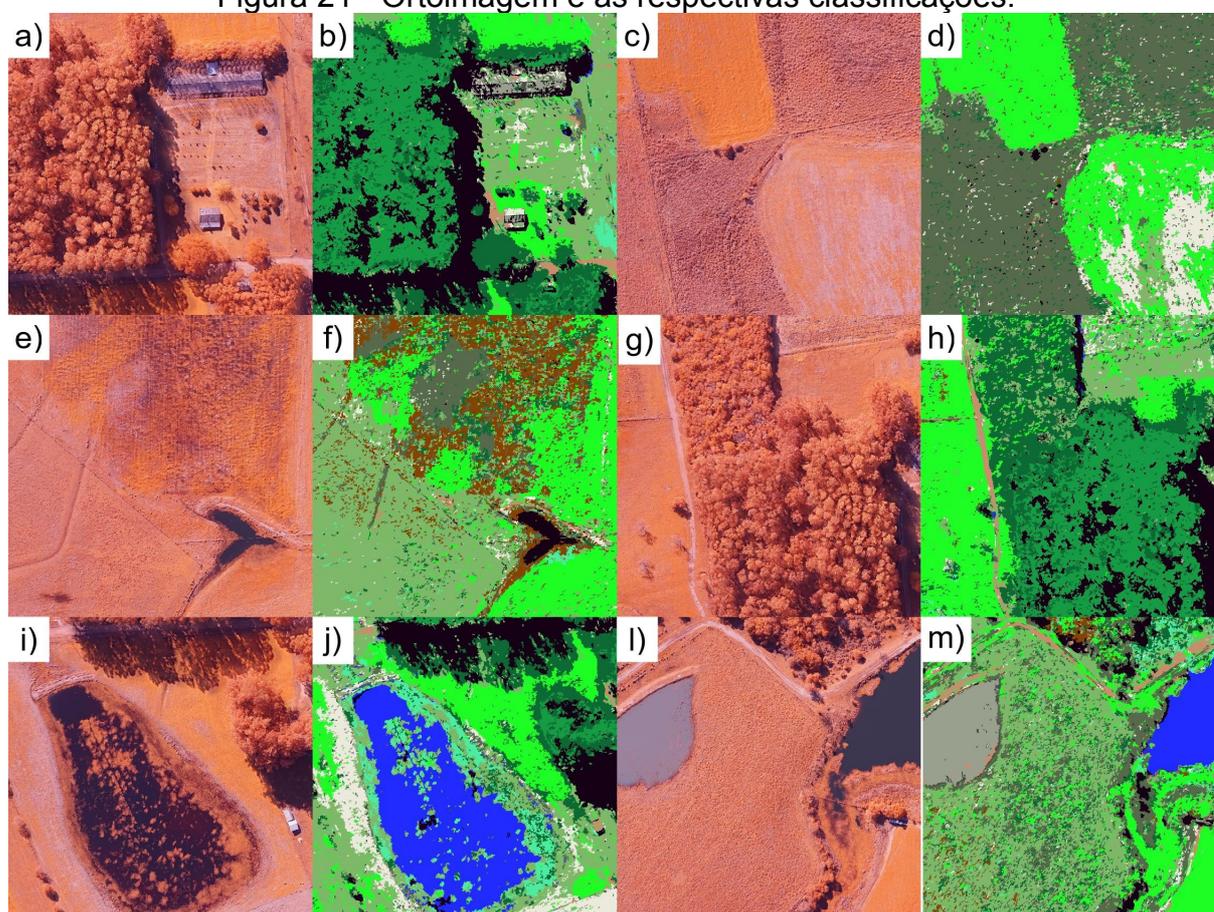
O voo foi realizado no inverno, nessa estação do ano, os ângulos de iluminação do sol são os menores do ano. Outro agravante desse problema foi o horário, pois o ângulo diminui ainda mais em horários distintos das 12h. Isso provocou maior sombreamento nas imagens. Como as imagens são de altíssima resolução espacial, mesmo as áreas com vegetação mais baixa tiveram sombreamento, o que ajudou a aumentar a confusão no momento da classificação.

Essas questões podem ser vistas na Figura 21a, na classe silvicultura, em que há sombras prolongadas sobre outras classes. Essas sombras misturadas com outras classes foram classificadas erroneamente, como é identificado na Figura 21b e Figura 21j, em que as bordas das sombras foram classificadas como mata nativa.

Já na construção, que está mais ao norte, há árvores que provocam sombras tênues, dificultando a classificação desse objeto na imagem (Figura 21b).

Como já mencionado, as imagens coletadas com VANT são de altíssima resolução espacial, isso faz com que essas imagens possuam uma alta variabilidade espectral. Essa variabilidade espectral pode ser traduzida como dificuldade na separação dessas classes, como é caso das classes mata nativa e silvicultura (Figura 21g). Entretanto, como foram utilizados outros atributos, o modelo por AD conseguiu discriminá-las (Figura 21h), utilizando o MDE e os atributos de texturas, isso é confirmado avaliando as 3 regras que classificam a classe silvicultura (Apêndice F).

Figura 21 - Ortoimagem e as respectivas classificações.



Classes	
 Mata nativa	 Solo exposto
 Silvicultura	 Campo
 Sombra	 Banhado
 Pastagem	 Macrófita
 Resteva	 Água/cinza
 Construção	 Água
	 Solo úmido

0 40 80 120 160 m



Uma classe complexa e com alta variabilidade espectral é o banhado (Figura 21c), dado que nessa classe há vegetação em senescência, sombras e áreas úmidas. Esse mesmo problema acontece na classe pastagem, como mostra a Figura 21c, pois essas pastagens foram plantadas em épocas distintas, contendo diferenças no vigor vegetativo e na densidade do dossel. No entanto, a classificação das classes banhado e pastagem, como mostra a Figura 21d, foram possíveis de serem discriminadas.

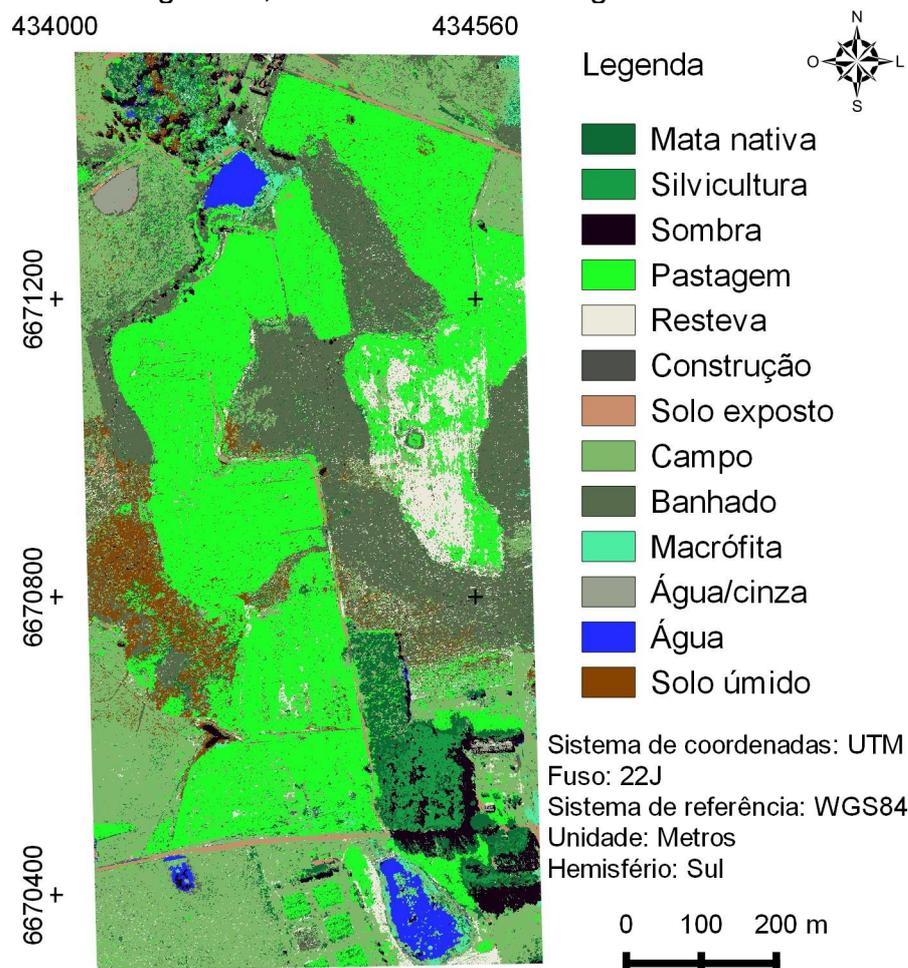
Essa discriminação pode ser atribuída ao método de coleta das amostras de treinamento, que foi feito de maneira regular sobre toda a área de estudo, assim conseguiu-se que essas amostras fossem representativas em relação às classes. Também pelo método de classificação que possibilitou o uso de atributos preditivos com diferentes distribuições, permitiu-se gerar regras que separam essas classes.

Esse tipo de problema se agrava quando essas classes acumulam a variabilidade espectral da classe com a semelhança espectral entre classes, como acontece para a macrófita. Na Figura 21i, há a ocorrência de macrófitas, e a metodologia empregada possibilitou discriminá-la das demais (Figura 21j). Contudo, ao analisar a Figura 21l, as macrófitas possuem maior vigor vegetativo, assemelhando-se à classe pastagem e diferenciando-se da apresentada na Figura 21i.

Essas questões de variabilidade também são vistas para outros atributos, como no caso da textura para a classe campo, representada na Figura 21l. A textura nesse local é diferente da vista na Figura 21e e 21a. A classificação dessa classe, nos locais onde as texturas são homogêneas, foi constatada uma boa correspondência (Figura 21b e Figura 21f), mas, onde a textura é específica do local, houve uma confusão com outras classes (Figura 21m).

Uma das vantagens do uso da OBIA é que a classificação não apresenta o efeito de “sal e pimenta”, entretanto avaliando a classificação na íntegra (Figura 22), também pode-se observar esse efeito. Isso ocorreu devido ao valor informado no parâmetro número mínimo de pixels da segmentação. Valores maiores diminuiriam esse efeito sobre a imagem e conseqüentemente, diminuiriam a escala de mapeamento. De modo geral, é encontrada uma boa correspondência com a ortoimagem (Figura 10).

Figura 22 - Classificação da ortomagem do modelo treinado com amostras do limiar igual 15, trial a zero e winnow igual a falso.



Na literatura são reportados trabalhos com valores de acurácias maiores que o encontrado neste trabalho, como o realizado por Laliberte e Rango (2009), em que foram discriminadas as classes solo exposto, gramíneas e arbustos, com uma acurácia global chegando a 90%, utilizando câmara com bandas no visível.

Também Xu et al. (2013) conseguiram diferenciar as classes água, arbustos, estradas e casas a partir de uma imagem coletada com uma câmara na banda do visível, obtendo valores de índice kappa superiores a 0,85.

Em classificações com um maior número de classes, os sensores possuem mais bandas, como é o caso do trabalho efetuado por Laliberte et al. (2011b), em que os autores avaliaram a separação de oito classes da cobertura da terra, utilizando uma câmara Mini MCA – 6, que possui seis bandas, conseguindo um valor. Obtendo como resultado um valor de 87% para a acurácia global e 0,83 para o índice kappa.

No estudo de Laliberte et al. (2011b), foi utilizada a mesma câmara Mini MCA – 6. Dado que neste presente estudo foram discriminadas 13 classes de cobertura da terra e que uma das bandas diminui o contraste entre as classes, o valor de índice kappa de 0,71 pode ser considerado como satisfatório.

Os principais resultados desse item estão relacionados ao parâmetro *winnow* do algoritmo C5.0. Avaliando as classificações com um nível de significância de 5%, não foi identificado melhora nas classificações quando o parâmetro *winnow* foi selecionado como verdadeiro. Foi identificada, entretanto, uma redução significativa no número de atributos preditores, que pode facilitar a interpretação da AD e a classificação da cobertura da terra.

Também constou-se que o classificador C5.0 sobreajustou-se aos dados de treinamento, quando o parâmetro *trial* aumentou. Perdendo o poder preditivo sobre os dados reais, no caso, as regiões da segmentação. Como esse algoritmo está disponível para ser alterado, futuros trabalhos podem modificá-lo para que a avaliação da reforço (*trial*) considere dados distintos do treinamento.

## 5 CONCLUSÃO

Os algoritmos desenvolvidos neste trabalho possibilitaram o emprego da metodologia proposta de maneira automatizada, integrando OBIA e o classificador C5.0. Como também, permitiu a classificação e a avaliação de 40 imagens. Outro benefício do uso dessas rotinas foi em relação à possibilidade de utilizar essas imagens sem convertê-las para outro tipo de dado.

A segmentação crescimento de regiões disponível no programa Spring possibilitou valores de RBSB próximos a 0, com melhores valores para os limiares 1, 2 e 5. Analisando visualmente as segmentações, identificou-se que o limiar igual a 15 resultou nas regiões mais próximas ao delineado pelo especialista. Também ao comparar as regiões formadas em relação às classes de cobertura da terra, identificou-se que o limiar igual a 50 delimitou melhor as classes sombra e construção. Com isso, pode-se considerar a segmentação por crescimento de regiões uma alternativa para gerar as regiões em imagens de altíssima resolução espacial, mas os valores dos limiares devem ser avaliados qualitativamente e quantitativamente para se decidir pelo melhor.

Os modelos gerados com distintos valores de ensaios (*trial*) apresentaram melhores ajustes aos dados de treinamento a partir do valor 10. No entanto, ao avaliá-los em relação às amostras de validação, ou seja, amostras que não foram utilizadas nas construções dos modelos, os valores de acurácias, no geral, não foram maiores para valores do *trial* superiores a 0. Constatou-se que esse parâmetro perdeu o poder de generalização ao tentar se ajustar aos dados de treinamento.

Nas construções dos modelos, ao escolher verdadeiro para o parâmetro *winnnow*, foram selecionados os atributos preditivos mais importantes. Considerando os 20 modelos com essa configuração, os atributos mais importantes foram a razão entre a banda do verde com a azul (*r\_v\_a*) e o MDE. Comparando esses modelos com os gerados para *winnnow* igual a falso, a um nível de significância de 5%, foram encontradas diferenças apenas para 4 valores de acurácias. Contudo, o maior ganho é na redução do número de atributos preditivos na construção dos modelos, que pode chegar a uma redução de aproximadamente 30%, facilitando a interpretação dos modelos.

O modelo treinado com amostras do limiar igual a 15, *winnnow* igual a falso e

*trial* igual a 0 resultou no valor de índice kappa 0,71, sendo o maior valor entre os modelos. O algoritmo C5.0 se mostrou eficiente, tanto no tempo de processamento para gerar os modelos por AD quanto na acurácia alcançada sobre imagens de altíssima resolução.

Nesse sentido, este trabalho contribuiu para a classificação da cobertura da terra em imagens coletadas por VANT, uma vez que se desenvolveu algoritmos para automatizar os processos da OBIA e para avaliar a classificação das regiões em relação às funções de reforço (*winnnow*) e de seleção do atributo (*winnnow*) do classificador por árvore de decisão C5.0.

## REFERÊNCIAS

- ADAMS, R. AND BISCHOF, L. **Seeded region growing**. *IEEE Transactions on pattern analysis and machine intelligence*, v. 16, n. 6, p. 641-647, 1994.
- AGISOFT, GUIDE PHOTOSCAN, 2015. Disponível em: <<http://www.agisoft.com/support/tutorials/intermediate-level/>>. Acessado em 20 set. 2014.
- ANAC (Agência Nacional de Aviação Civil), Instrução Suplementar (IS) 21-002 Revisão A. Emissão de Certificado de Autorização de Voo Experimental para Veículos Aéreos Não Tripulados, 2012.
- APLIN, P. AND SMITH, G.M. **Introduction to object-based landscape analysis**. *International Journal of Geographical Information Science*, v. 25, n. 6, p. 869-875, 2011.
- BAATZ, M., AND SCHAEPE, A. **Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation**. 2000. Disponível em: <[http://www.ecognition.com/sites/default/files/405\\_baatz\\_fp\\_12.pdf](http://www.ecognition.com/sites/default/files/405_baatz_fp_12.pdf)>. Acesso em 1 de dez. 2014.
- BERNI, J.; ZARCO-TEJADA, P.; SUAREZ, L. AND FEREREZ, E. **Thermal and narrow-band multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle**. *IEEE Transactions On Geoscience And Remote Sensing*, v. 47, n. 3, p. 722-738, 2009.
- BINS, L., FONSECA, L. e ERTHAL, G. Satellite imagery segmentation: a region growing approach. In SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8, Salvador, p. 677–680.
- BLASCHKE, T. **Object based image analysis for remote sensing**, *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 65, n. 1, p. 2-16, 2010.
- BROWN, D. C. **Decentering distortion of lenses**. *Photogrammetric Engineering*. v. 32, n. 3, p. 444–462, 1966.
- CARVALHO, M. V.; KUX, H. J. H. AND FLORENZANO, T. G. Urban land cover classification with worldview-2 images using data mining and object-based image analysis. In: INTERNATIONAL CONFERENCE ON GEOGRAPHIC OBJECT BASED IMAGE ANALYSIS, 4, Rio de Janeiro, 2012. **Proceeding**. Rio de Janeiro, 2012.
- CHAUDHURI, D AND AGRAWAL, A. **Split-and-merge Procedure for Image Segmentation using Bimodality Detection Approach**. *Defence Science Journal*, v. 60, n. 3, p. 290-301, 2010.
- CHUTIA, D.; BHATTACHARYYA, D. K.; KALITA, R. AND SUDHAKAR, S. **OBCsvmFS: Object-Based Classification supported by Support Vector Machine Feature Selection approach for hyperspectral data**. *Journal Geomatics*, v. 8, n. 1, 2014.

COLOMINA, I. AND MOLINA, P. **Unmanned aerial systems for photogrammetry and remote sensing: A review**. *Journal of Photogrammetry and Remote Sensing*, v. 92, p. 79-97, 2014.

CONGALTON, R. G. **A review of assessing the accuracy of classifications of remotely sensed data**. *Remote Sensing of Environment*, v. 37, p. 35-46. 1991.

DEAN, A.M. AND SMITH, G.M. **An evaluation of per-parcel land cover mapping using maximum likelihood class probabilities**. *International Journal of Remote Sensing*, v. 24, p. 2905-2920, 2003.

ESPINDOLA G.; CAMARA G.; REIS I.; BINS L. AND MONTEIRO A. **Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation**. *International Journal of Remote Sensing*. v. 27, p. 3035-3040, 2006.

ESTRADA, F. J. AND A. JEPSON, D. Quantitative Evaluation of a Novel Image Segmentation Algorithm. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2005, San Diego. **Annals of Institute of Electrical and Electronic Engineers (IEEE)**, San Diego, v. 2, 2005, p.132 – 1139.

EVERAERTS, J. The use of unmanned aerial vehicles (UAVs) for remote sensing and mapping. In: INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, 21, 2008, Beijing, **Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Beijing, 2008, p.1187-1192.

EZEQUIEL, C.A.F.; CUA, M.; LIBATIQUE, N.C.; TANGONAN, G.L.; ALAMPAY, R.; LABUGUEN, R.T.; FAVILA, C.M.; HONRADO, J.L.E.; CANOS, V.; DEVANEY, C.; LORETO, A.B.; BACUSMO, J. AND PALMA, B. UAV aerial imaging applications for post-disaster assessment, environmental management and infrastructure development, In: UNMANNED AIRCRAFT SYSTEMS (ICUAS), 2014 INTERNATIONAL CONFERENCE ON, Orlando, **Annals of Institute of Electrical and Electronic Engineers (IEEE)**. Orlando, 2014, p. 274,283.

FAA (Federal Aviation Administration), Unmanned Aircraft Systems. Disponível em: <<https://www.faa.gov/uas/>>. Acessado em 20 de nov. 2014.

FEITOSA, R. Q.; COSTA, G. A.; CAZES, T. B. ; FEIJÓ, B. A. Genetic Approach for the Automatic Adaptation of Segmentation Parameters. In: INTERNATIONAL CONFERENCE ON OBJECT-BASED IMAGE ANALYSIS (OBIA), 1, 2006. **Proceedings**. Salzburg, Stefan Lang, Thomas Blaschke & Elisabeth Schöpfer (Editors) 2006, v. 36, n. 4, 2006.

FERNANDES, M. R.; AGUIAR, F. C.; SILVA, J. M.N.; FERREIRA, M. T. AND 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. 32, p. 79 – 91, 2014.

FERREIRA, R. Uma abordagem multiescalar, multicritério para a segmentação de imagens. 2011. Dissertação (Mestrado em Engenharia Elétrica) -Pontifícia Universidade Católica do Rio de Janeiro –PUC-Rio, Rio de Janeiro. 2011.

FLENER, C.; VAAJA, M.; JAAKKOLA, A.; KROOKS, A.; KAARTINEN, H.; KUKKO, A.; KASVI, E.; HYYPPÄ, H.; HYYPPÄ, J.; ALHO, P. **Seamless mapping of river channels at high resolution using mobile lidar and uav-photography.** *Remote Sensing*, Beijing, v.5, n.12, p. 6382-6407. 2013.

FLYNN, K.F. AND CHAPRA, S.C. **Remote sensing of submerged aquatic vegetation in a shallow non-turbid river using an unmanned aerial vehicle.** *Remote Sensing*, v. 6, p. 12815-12836, 2014.

FOODY, G.M. AND ARORA, M.K. **An evaluation of some factors affecting the accuracy of classification by an artificial neural network.** *International Journal of Remote Sensing*, v.18, p.799-810, 1997.

FRASER, C.S. **Photogrammetric Measurement to One Part in a Million.** *Photogrammetric Engineering and Remote Sensing*, v. 58, n. 3, p. 305–310, 1992.

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

FUYI, T.; CHUN, B.B.; JAFRI, M. Z. M.; SAN, L. H.; ABDULLAH, K. AND TAHRIN, N. M. Land Cover Use Mapping Using Multi Band Imageries Captured By Cropcam Ed By Cropcam Unmanned Aerial Vehicle Autopilot(Uav) Over Penang Island, Malaysia. In: UNMANNED/UNATTENDED SENSORS AND SENSOR NETWORK, 9, Edinburgh, **Proc SPIE**. v. 8540, 2012.

GINI, R.; PASSONI, D.; PINTO, P. AND SONA, G. **Use of Unmanned Aerial Systems for multispectral survey and tree classification: a test in a park area of northern Italy.** *European Journal of Remote Sensing*, v. 47, p. 251-269, 2014.

HAMEDIANFAR, A.; SHAFRI, H. Z. M.; MANSOR, S.AND AHMAD, N. **Combining data mining algorithm and object-based image analysis for detailed urban mapping of hyperspectral images.** *J. Appl. Remote Sens*, v. 8, n. 1, 2014.

HAN, J.H.; KWON, J.H.; LEE, I.; CHOI, K. Position and Attitude Determination for UAV-Based GPS, IMU and AT without GCPs. In: INTERNATIONAL WORKSHOP ON MULTI-PLATFORM/MULTI-SENSOR REMOTE SENSING AND MAPPING (M2RSM), 2011, Xiamen, **Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Xiamen, 2011, p. 1-5

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

HARALICK, R. Statistical and structural approaches to texture, **Proceedings of the IEEE**, v. 67, n. 5, p. 786-804, 1979.

HAUBECK, K. AND PRINZ, T. A. Uav-Based Low-Cost Stereo Camera System for Archaeological Surveys - Experiences from Doliche (Turkey). In: UAV-G, 2013, ROSTOCK. THE INTERNATIONAL ARCHIVES OF THE PHOTOGRAMMETRY, REMOTE SENSING AND SPATIAL INFORMATION SCIENCES, Enschede, 40, 2013, **Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, p. 195-200, 2013.

HELLESEN, T. AND MATIKAINEN, L. **An Object-Based Approach for Mapping Shrub and Tree Cover on Grassland Habitats by Use of LiDAR and CIR Orthoimages**. *Remote Sensing*. v. 5, n. 2, p. 558-583. 2013.

HEUMANN, B.W. **An Object-Based Classification of Mangroves Using a Hybrid Decision Tree—Support Vector Machine Approach**. *Remote Sensing*, v. 3, n. 11, p. 2440-2460, 2011.

HUDSON, W.D. AND RAMM, C.W. **Correct formulation of the kappa coefficient of agreement**. *Photogrammetric Engineering & Remote Sensing*, Maryland, v.53, n.4, p.421-422, 1987.

HUNT, E.R., JR.; HIVELY, W.D.; FUJIKAWA, S.J.; LINDEN, D.S.; DAUGHTRY, C.S.T. AND MCCARTY, G.W. **Acquisition of NIR-Green-Blue Digital Photographs from Unmanned Aircraft for Crop Monitoring**. *Remote Sens*. v. 2, n. 1, p. 290-305, 2010.

ICAO, 2011. ICAO Circular 328, **Unmanned Aircraft Systems (UAS). Technical Report**. International Civil Aviation Authority. Montreal, Canada.

JAPAN ASSOCIATION OF REMOTE SENSING. Concepts Maximum Likelihood Classifier, 1996. Disponível em: <<http://wtlab.iis.u-tokyo.ac.jp/~wataru/lecture/rsgis/rsnote/cp11/cp11-7.htm>>. Acessado em 15 dez. 2014.

JENSEN, J. R. (1949) **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres** / tradução José Carlos Neves Epiphanyo et al. São José dos Campos. SP. 2009

JIA, K.; LIANG, S.; WEI, X.; YAO, Y.; SU, Y.; JIANG, B.; WANG, X. **Land cover classification of landsat data with phenological features extracted from time series modis NDVI data**. *Remote Sensing*, Beijing, v. 6, n. 11, p.11518-11532, 2014.

JOHANSEN, K., BARTOLO, R. AND PHINN, S. SPECIAL FEATURE — **Geographic Object-Based Image Analysis**, *Journal of Spatial Science*, v. 55, n. 1, p. 3-7, 2010.

JOSHI, A.; JOSHI J. R.; SHRESTHA, N.; SHRESTHA, S. AND GAUTAM, S. **Object Based Land Cover Extraction Using Open Source Software**. *Nepalese Journal of Geoinformatics*. v. 12, 2013.

KAMAL, M.AND PHINN, S. **Hyperspectral Data for Mangrove Species Mapping: A Comparison of Pixel-Based and Object-Based Approach**. *Remote Sensing*. v. 3, n. 10, p. 2222-2242, 2011.

KARATHANASSI, V.; LOSSIFIDIS, C. AND ROKOS, D. **A texture-based classification method for classifying built areas according to their density.** *International Journal Remote Sensing*, v. 21, p. 1807-1823, 2000.

KELCEY, J. AND LUCIEER, A. **Sensor Correction of a 6-Band Multispectral imaging sensor for UAV remote sensing.** *Remote Sensing*, v. 4, n. 5, p. 1462-149, 2012.

KUHN, M. AND JOHNSON, K. *Applied Predictive Modeling*, Springer, New work, 2013.

LALIBERTE A. S., FREDRICKSON,E. L. AND RANGO, A. **Combining Decision Trees with Hierarchical Object-oriented Image Analysis for Mapping Arid Rangelands.** *Photogrammetric Engineering & Remote Sensing*, v. 73, n. 2, p. 197–207, 2007.

LALIBERTE, A.; BROWNING, D. AND RANGO, A. **A comparison of three feature selection methods for object-based classification of sub-decimeter resolution UltraCam-L imagery.** *International Journal of Applied Earth Observation and Geoinformation*, v.15, p. 70-78, 2012.

LALIBERTE, A. S.; WINTERS, C. AND RANGO, A. **UAS remote sensing missions for rangeland applications.** *Geocarto International*, v. 26, n. 2, p. 141-156, 2011a.

LALIBERTE, A.S.; GOFORTH, M.A.; STEELE, C.M. AND RANGO, A. **Multispectral remote sensing from unmanned aircraft: image processing workflows and applications for rangeland environments.** *Remote Sensing*. v. 3, n. 11, p. 2529-2551, 2011b.

LALIBERTE, A.S. AND RANGO, A. **Image processing and classification procedures for analysis of sub - decimeter imagery acquired with an unmanned aircraft over arid rangelands.** *GIScience & Remote Sensing*, v. 48, n. 1, p. 4-23. 2011c.

LALIBERTE, A. AND RANGO, A. **Texture and scale in object-based analysis of subdecimeter resolution unmanned aerial vehicle (UAV) imagery.** *IEEE Transactions on Geoscience and Remote Sensing*, v.47, p. 1-10, 2009.

LANDIS, J.R. AND KOCH, G.G. **The measurement of observer agreement for categorical data.** *Biometrics*, v.33, n.1, p. 159-174, 1977.

LECHNER, M.; FLETCHER, A.; JOHANSEN, K.; AND ERSKINE, P. **Characterising Upland Swamps Using Object-Based Classification Methods And Hyper-Spatial Resolution Imagery Derived From An Unmanned Aerial Vehicle.** In: INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, 27, 2012, Melbourne, **Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Melbourne, 2012, p. 101-106.

LI, Y.; GONG, J. H.; ZHU, J.; YE, L.; SONG, Y. AND Q.YUE, Y. J. **Efficient dam break flood simulation methods for developing a preliminary evacuation plan**

**after the Wenchuan Earthquake**, *Natural Hazards Earth System Sciences*, v.12, p. 97-106, 2012.

LONGHITANO, G. A. **VANTS para sensoriamento remoto: aplicabilidade na avaliação e monitoramento de impactos ambientais causados por acidentes com cargas perigosas**. Dissertação de Mestrado em Engenharia de Transportes, Escola Politécnica, Universidade de São Paulo, São Paulo, 2010.

LU, D AND WENG, Q. **A survey of image classification methods and techniques for improving classification performance**. *International Journal of Remote Sensing*, v. 28, p. 823-870. 2007.

MANCINI, F.; DUBBINI, M.; GATTELLI, M.; STECCHI, F.; FABBRI, S. AND GABBIANELLI, G. **Using Unmanned Aerial Vehicles (UAV) for High-Resolution Reconstruction of Topography: The Structure from Motion Approach on Coastal**. *Environments Remote Sensing*, v. 5, p. 6880-6898, 2013.

MORANDUZZO, T. AND MELGANI, F. **Automatic Car Counting Method for Unmanned Aerial Vehicle Images**, *Geoscience and Remote Sensing, IEEE Transactions*, v. 52, n. 3, p.1635-1647, 2014.

MYBURGH, G. AND NIEKERK, A. V. **Effect of 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.

NEUBERT, M.; HEROLD, H; MEINEL, G. Evaluation of Remote Sensing Image Segmentation Quality – Further Results and Concepts. In: INTERNATIONAL CONFERENCE ON OBJECT-BASED IMAGE ANALYSIS, 1, 2006, Salzburg, **Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Salzburg, 2006.

NIETHAMMER, U.; JAMES, M.; ROTHMUND, S.; TRAVELLETTI, J. AND JOSWIG, M. **UAV-based remote sensing of the Super-Sauze landslide: Evaluation and results**. *Engineering Geology*, v.128, n.1, p. 2 - 11, 2012.

OLIVEIRA, J. C. Índice para avaliação de segmentação (IAVAS): uma aplicação em agricultura. 2002. 160 p. Dissertação de Mestrado em Sensoriamento Remoto no Programa de Pós-graduação no Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2002. Disponível em: <http://urlib.net/sid.inpe.br/MTC-m13@80/2006/12.21.11.14>. Acesso em 10 dezembro 2014.

PATIL, N.; LATHI, R. AND CHITRE, V. **Comparison of C5.0 & CART Classification algorithms using pruning technique**. *International Journal of Engineering Research & Technology*. v. 1, n. 4, 2012.

PEKKARINEN, A. **Image segment – based spectral features in the estimation of timber volume**. *Remote Sensing of Environments*, v. 82, p. 349 – 359, 2002.

POLSKI, P. DHS View of Unmanned Aerial Vehicle Needs. In: Unmanned Unlimited

Technical Conference, 3, Chicago, 2004, p. 20–23.

QUINLAN, J. R. **Improved use of continuous attributes in C4.5.** *Journal of Artificial Intelligence Research*, v. 4, p. 77-90, 1996.

QUINLAN, J. R. AND RIVEST, R. L. **Inferring decision trees using minimum description length principle.** *Information and Computation*, v. 80, p. 227-248, 1989.

QUINLAN, J. R. **C5.0: An Informal Tutorial.** Australian, 2013. Acessado em: 20 set. 2014. Online. Disponível em: <http://www.rulequest.com/see5-unix.html>.

SAARINEN, N.; VASTARANTA, M.; VAAJA, M.; LOTSARI, E.; JAAKKOLA, A.; KUKKO, A.; KAARTINEN, H.; HOLOPAINEN, M.; HYYPPÄ, H.; ALHO, P. **Area-based approach for mapping and monitoring riverine vegetation using mobile laser scanning.** *Remote Sensing*, Beijing, v. 5, n.10, p. 5285-5303, 2013.

SCIKIT-LEARN, Classifier comparison, 2014. Disponível em: <[http://scikit-learn.org/stable/auto\\_examples/plot\\_classifier\\_comparison.html](http://scikit-learn.org/stable/auto_examples/plot_classifier_comparison.html)>. Acessado em 20 set. 2014.

SILVA, P. M , S.; CÂMARA, G.; CARTAXO, R.; SOUZA, M.; DALTON, M. AND ESCADA, M. I. S. Mining patterns of change in remote sensing image databases. In: INTERNATIONAL CONFERENCE ON DATA MINING, 5, 2005, Washington, **Proceedings IEEE Computer Society**, 2005. p. 362–369.

TEODORO, A. C. AND ARAÚJO, R. **Exploration of the OBIA methods available in SPRING noncommercial software to UAV data processing.** *SPIE Proceedings*, v. 9245, p. 1-11, 2014.

TORRES-SÁNCHEZ, J; LÓPEZ-GRANADOS, F.; DE CASTRO, A. I. AND PEÑA-BARRAGÁN, J, M. **Configuration and Specifications of an Unmanned Aerial Vehicle (UAV) for Early Site Specific Weed Management.** *PLoS One*. v. 8, n. 3, 2013.

TORRES-SÁNCHEZ, J.; PEÑA, J.M.; DE CASTRO, A.I. AND LÓPEZ-GRANADOS, F. **Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV.** *Computers and Electronics in Agriculture*. v. 103, p. 104-113, 2014.

TURNER, D.; LUCIEER, A. AND 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*, Beijing, v. 4, n. 5, p. 1392-1410, 2012.

TURKER, M. AND SUMER, E. **Building-based damage detection due to earthquake using the watershed segmentation of the post-event aerial images.** *International Journal of Remote Sensing*, v. 29, n. 11, p. 3073–3089, 2008

WATTS, A. C.; AMBROSIA, V. G. AND HINKLEY, E. **Unmanned Aircraft Systems in Remote Sensing and Scientific Research: Classification and Considerations of**

**Use.** *Remote Sensing*, v. 4, n. 6, p. 1671-1692, 2012.

WESTOBY, M.; BRASINGTON, J.; GLASSER, N.; HAMBREY, M. AND REYNOLDS, J. **Structure-from-Motion' photogrammetry: A low-cost, effective tool for geoscience applications.** *Geomorphology*, v. 179, p. 300 – 314, 2012.

XU, Y. AND DUAN, F. Color space transformation and object oriented based information extraction of aerial images, In: INTERNATIONAL CONFERENCE ON GEOINFORMATICS, 21, 2013, Kaifeng, **Proceedings IEEE**, 2013, p. 20-22.

YASTIKLI, N.; BAGCI, I.AND BESER, C. The processing of image data collected by light UAV systems for GIS Data Capture and Updating. In: SERVING SOCIETY WITH GEOINFORMATICS, 40, 2013, Turkey. **Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Enschede, 2013, p. 267-270.

## **APÊNDICES**

## APÊNDICE A – Código para avaliação nas imagens segmentadas

```

import gdal
import os
import numpy as np
path = 'C:/LuisFernando/Projeto_dirsse/seg_mod/img/'
def get_imlist(path):
    return [os.path.join(path,f) for f in os.listdir(path) if f.endswith('.tif')]
validacao_seg = 'validacao_seg.tif'
gdal.AllRegister()
ds = gdal.Open(validacao_seg, gdal.GA_ReadOnly)
segmentacoes_dic={}
band_validacao = ds.GetRasterBand(1).ReadAsArray().astype(np.int32)
files_attr = get_imlist(path)
for p in files_attr:
    nome = p.split('/')[1].split('.')[0]
    gdal.AllRegister()
    ds = gdal.Open(p, gdal.GA_ReadOnly)
    n_bands = ds.RasterCount
    band = ds.GetRasterBand(1).ReadAsArray().astype(np.int32)
    segmentacoes_dic[nome]=band
band_validacao=np.where(band_validacao <= 0,0,band_validacao )
minValue= np.min(band_validacao)
maxValue = np.max(band_validacao)
area_total=[]
dic_aux={}
for i in segmentacoes_dic :
    dic_aux[i]=[]
for v_reg in xrange(minValue+1, maxValue+1):
    rows,cols = np.where(band_validacao == v_reg)
    n_total_ND_val =band_validacao[rows,cols].shape
    area_val =n_total_ND_val[0] * 0.0225
    area_total.append(area_val)
    for at in segmentacoes_dic:
        ids_intersec = segmentacoes_dic[at][rows, cols]
        freq =np.bincount(ids_intersec)
        maior_freq_intersec=np.max(freq)
        id_seg_maior_freq=np.where(freq == maior_freq_intersec)
        n_total_ND_seg = segmentacoes_dic[at][segmentacoes_dic[at] == id_seg_maior_freq].shape[0]
        fn= n_total_ND_val - maior_freq_intersec
        fp = n_total_ND_seg - maior_freq_intersec
        rbsb_parcial = (fn+fp)/area_val
        dic_aux[at].append(rbsb_parcial)
for seg in dic_aux:
    rbsb = (1/sum(area_total))* sum(dic_aux[seg])
    print seg, rbsb

```

## APÊNDICE B – Rotina para calcular valores médios dos atributos para as regiões

```

import gdal
import os
import numpy as np
import csv
path = 'C:/img/'
def get_imlist(path):
    return [os.path.join(path,f) for f in os.listdir(path) if f.endswith('.tif')]
file_seg = 'segmentacao_10.tif'
gdal.AllRegister()
ds = gdal.Open(file_seg, gdal.GA_ReadOnly)
bandas_dic={}
segmentacao = ds.GetRasterBand(1).ReadAsArray().astype(np.int32)
geoTransform = ds.GetGeoTransform()
colunas = ds.RasterXSize
linhas = ds.RasterYSize
files_attr = get_imlist(path)
for p in files_attr:
    nome = p.split('/')[-1].split('.')[0]
    gdal.AllRegister()
    ds = gdal.Open(p, gdal.GA_ReadOnly)
    n_bands = ds.RasterCount
    if n_bands > 1:
        for i in xrange(1, n_bands+1):
            band = ds.GetRasterBand(i).ReadAsArray()
            nome=nome+'_band'+str(i)
            bandas_dic[nome]=band
    else:
        band = ds.GetRasterBand(1).ReadAsArray()
        bandas_dic[nome]=band
minValue= np.min(segmentacao)
maxValue = np.max(segmentacao)
colunas = bandas_dic.keys()
colunas.insert(0,'fid')
file_csv= open('C:/arquivo.csv','wt')
writer_csv = csv.writer(file_csv,delimiter='\t',)
writer_csv.writerow(tuple(colunas))
for v_reg in xrange(minValue, maxValue+1):
    rows,cols = np.where(segmentacao == v_reg)
    mean = [v_reg]
    for at in bandas_dic:
        v=np.mean(bandas_dic[at][rows, cols])
        v=np.around(v,3)
        mean.append(v)
    writer_csv.writerow(tuple(mean))
file_csv.close()

```

## APÊNDICE C – Algoritmo para calcular os atributos geométricos das regiões

```

import gdal
import numpy as np
import math
from skimage import measure
import csv
file = 'imagem_segmentada.tif'
gdal.AllRegister()
ds = gdal.Open(file, gdal.GA_ReadOnly)
banda = ds.GetRasterBand(1).ReadAsArray()
banda=banda.astype(np.int32)
regiao_seg=measure.regionprops(banda)
file_csv= open('seg.csv','wt')
writer_csv = csv.writer(file_csv,delimiter='\t,')
writer_csv.writerow(('fid','n_pixel','perimetro','area_seg','ajus_ret','ajus_circ','compactacao','ind_form','assimetria'))
for i, regprop in enumerate(regiao_seg):
    n_pixel = regprop.area
    area_reg = (n_pixel * 0.0225)
    ret = regprop.bbox
    ajus_ret = (((ret[2]-ret[0])*0.15)*((ret[3]-ret[1])*0.15)-area_reg)/ area_reg
    compactacao = ((ret[2]-ret[0])*(ret[3]-ret[1]))/ n_pixel
    raio = (math.sqrt((ret[2]-ret[0])**2 + (ret[3]-ret[1])**2))/2
    ajus_circ = (math.pi*((raio*0.15)**2)-area_reg)/ area_reg
    perim_reg = regprop.perimeter*0.15
    ind_form= perim_reg/(4*math.sqrt(area_reg))
    assimetria = 1.0 - (float(ret[2]-ret[0])/(ret[3]-ret[1]))
    writer_csv.writerow(i,n_pixel, perim_reg, area_reg, ajus_ret,ajus_circ, | compactacao,ind_form,assimetria)
file_csv.close()

```

## APÊNDICE D – Código para classificar as segmentações

```

import numpy as np
import gdal
files_csv=["C:/mean_spec.csv", 'C:/mean_textura.csv', 'seg_geometrias.csv']
for f in files_csv:
    dados=np.recfromcsv(f,delimiter='\t',case_sensitive=True)
    fields = dados.dtype.fields.keys()
    for field in fields:
        exec(field+'=dados[field]')
strAD = 'AD_seg'
listAD = strAD.split("\n")
listAuxAD = strAD.split("\n")
listAuxAD = [w.replace('...', '#')for w in listAD]
listAuxAD = [w.replace(':', '#')for w in listAuxAD]
listAuxAD = [w.replace(' ', '#')for w in listAuxAD]
numEsp = [w.count('#')for w in listAuxAD]
print listAuxAD
del listAuxAD
inicioAD = listAD.index('Decision tree:')
cond=""
controlePrimeiraLinha = 0
for index,value in enumerate(listAD):
    valueLista = value.split()
    valueLista =[i.replace('...', '') for i in valueLista]
    valueLista =[i.replace(':', '') for i in valueLista]
    valueLista =[i for i in valueLista if i != ""]
    if index < (inicioAD+2):
        pass
    elif listAD[index].find('Evaluation') != -1:
        break
    elif controlePrimeiraLinha == 0:
        controlePrimeiraLinha =1
        if listAD[index].find('(') != -1:
            cond = cond+'np.where( '+str(valueLista[0])+str(valueLista[1])+str(valueLista[2])+ ' , '+ str(valueLista[3])+ ' , '
        else:
            cond = cond+'np.where( '+str(valueLista[0])+str(valueLista[1])+str(valueLista[2])+ ' , '
    elif listAD[index].find('...') != -1:
        if listAD[index].find('(') != -1:
            cond = cond + ' np.where( '+ str(valueLista[0])+str(valueLista[1])+str(valueLista[2])+ ' , '+ str(valueLista[3]) + ' , '
        else:
            cond = cond + ' np.where( '+ str(valueLista[0])+str(valueLista[1])+str(valueLista[2])+ ' , '
    else:
        if numEsp[index] > numEsp[index+1]:
            numEsp[index]-numEsp[index+1]
        if listAD[index].find('(') != -1:
            if listAD[index+1]==" ":
                cond= cond +' '+str(valueLista[3])+ ( ' ) * ( numEsp[index]-numEsp[index+1])
            else:
                cond= cond +' '+str(valueLista[3])+ ( ' ) * ( numEsp[index]-numEsp[index+1]))+ ' , '
        else:
            pass
    cond = cond +' ) '
classificacao=eval( cond)
file = 'C:/segmentacao.tif'
gdal.AllRegister()
ds = gdal.Open(file, gdal.GA_ReadOnly)
ds_raster = gdal.Open(file, gdal.GA_ReadOnly)
ds.GetRasterBand(1).SetNoDataValue(0)
banda1 = ds.GetRasterBand(1).ReadAsArray()
geoTransform = ds.GetGeoTransform()
proj = ds_raster.GetProjection()
colunas = ds.RasterXSize
linhas = ds.RasterYSize
band_write=np.zeros((linhas, colunas), dtype= np.int16)
for i, classe in enumerate(classificacao,1):
    band_write[np.where(banda1 == i)] = classe
driver = ds.GetDriver()
outDataset = driver.Create('C:/class_seg.tif', colunas,linhas, 1,gdal.GDT_Int16)
outBand = outDataset.GetRasterBand(1)
outBand.SetNoDataValue(0)
outBand.WriteArray( band_write )
outDataset.SetGeoTransform(geoTransform)
outDataset.SetProjection(proj)

```

## APÊNDICE E – Algoritmo de validação das classificações

```

import csv
import gdal
import os
import numpy as np
from tempfile import TemporaryFile
outfile=TemporaryFile()
from statsmodels.stats.inter_rater import cohens_kappa
path = 'C:/classificacoes/'
def get_imlist(path):
    return [os.path.join(path,f) for f in os.listdir(path) if f.endswith('.tif')]
validacao_seg = 'C:/validacao_classificacoes.tif'
gdal.AllRegister()
ds = gdal.Open(validacao_seg, gdal.GA_ReadOnly)
classificacoes_dic={}
band_validacao = ds.GetRasterBand(1).ReadAsArray().astype(np.int32)
files_clas = get_imlist(path)
for p in files_clas:
    nome = p.split('/')[-1].split('.')[0]
    gdal.AllRegister()
    ds = gdal.Open(p, gdal.GA_ReadOnly)
    band = ds.GetRasterBand(1).ReadAsArray().astype(np.int32)
    classificacoes_dic[nome]=band
f = open('/home/ruiz/Downloads/mestrado/validacao_class_seg_15_b.txt','w')
f.write('\t')
f.write('kappa\tvar_kappa\tacuracia_global\n')
classes=[1,2,3,4,5,6,7,8,9,10,11,12,13]
for at in classificacoes_dic:
    matriz_confusao = []
    for i in classes:
        aux = classificacoes_dic[at][band_validacao==i]
        aux= np.append(aux,14)
        matriz_confusao.append(np.bincount(aux).tolist())
    matriz_confusao= np.asarray(matriz_confusao)[:,:-1]
    res = cohens_kappa(matriz_confusao.transpose())
    acuracia_global = float(np.sum(matriz_confusao.diagonal()))/float(np.sum(matriz_confusao))
    f.write(at)
    f.write('\t')
    f.write(str(round(res.kappa,3)))
    f.write('\t')
    f.write(str(round(res.var_kappa,12)))
    f.write('\t')
    f.write(str(round(acuracia_global,3)))
    f.write('\n')
f.close()

```

## APÊNDICE F – Árvore de decisão

```

r_v_a > 1.163:
...MDE <= 34.483:
: ...entr_45 <= 0.888:
: : ...IVP > 230.021:
: : : ...contr_45 <= 10.321: pastagem (214/5)
: : :   contr_45 > 10.321:
: : : : ...MDE <= 25.06: mata nativa (2)
: : : :   MDE > 25.06: pastagem (3)
: : : : IVP <= 230.021:
: : : : ...IVP <= 211.627:
: : : : : ...ASM_45 > 0.134: campo (3.4/0.4)
: : : : :   ASM_45 <= 0.134:
: : : : : : ...verde <= 91.933: pastagem (2)
: : : : : :   verde > 91.933: solo úmido (5/1)
: : : : : IVP > 211.627:
: : : : : ...contr_90 > 7.827: pastagem (88/2)
: : : : :   contr_90 <= 7.827:
: : : : : : ...r_ivp_a <= 2.337: campo (15/1)
: : : : : :   r_ivp_a > 2.337:
: : : : : : : ...area_seg <= 183.22: pastagem (12/3)
: : : : : : :   area_seg > 183.22: solo úmido (3/1)
: : : : : entr_45 > 0.888:
: : : : : ...corr_45 <= -0.249: pastagem (6/1)
: : : : :   corr_45 > -0.249:
: : : : : : ...r_v_a > 1.368:
: : : : : : : ...contr_135 <= 13.538: solo úmido (7/1)
: : : : : : :   contr_135 > 13.538: pastagem (7/1)
: : : : : : : r_v_a <= 1.368:
: : : : : : : ...ASM_45 > 0.13: mata nativa (4/1)
: : : : : : :   ASM_45 <= 0.13:
: : : : : : : : ...corr_45 > -0.074: banhado (6/1)
: : : : : : : :   corr_45 <= -0.074:
: : : : : : : : : ...r_ivp_v <= 2.03: campo (10/1)
: : : : : : : : :   r_ivp_v > 2.03:
: : : : : : : : : : ...area_seg <= 4.5: mata nativa (4)
: : : : : : : : : :   area_seg > 4.5: solo úmido (2)
: : : : : MDE > 34.483:
: : : : : ...azul <= 73.946:
: : : : : : ...entr_0 <= 1.001: sombra (3.3)
: : : : : :   entr_0 > 1.001: mata nativa (5.4)
: : : : : : azul > 73.946:
: : : : : : : ...MDE > 43.456:
: : : : : : : : ...MDE <= 54.946: mata nativa (6/1)
: : : : : : : :   MDE > 54.946: silvicultura (7)
: : : : : : : : MDE <= 43.456:
: : : : : : : : : ...IVP <= 216.988:
: : : : : : : : : : ...r_ivp_v > 2.09: mata nativa (3/1)
: : : : : : : : : :   r_ivp_v <= 2.09:
: : : : : : : : : : : ...MDE <= 36.161: campo (4)
: : : : : : : : : : :   MDE > 36.161:
: : : : : : : : : : : : ...MDE <= 38.333: macrófita (5)
: : : : : : : : : : : :   MDE > 38.333: campo (2)
: : : : : : : : : : : IVP > 216.988:
: : : : : : : : : : : ...contr_45 > 10.545: mata nativa (5)
: : : : : : : : : : :   contr_45 <= 10.545:
: : : : : : : : : : : : ...ASM_90 <= 0.087: mata nativa (2)
: : : : : : : : : : : :   ASM_90 > 0.087:
: : : : : : : : : : : : : ...ASM_0 > 0.093: pastagem (29/6)
: : : : : : : : : : : : :   ASM_0 <= 0.093:
: : : : : : : : : : : : : : ...ASM_0 <= 0.09: pastagem (2)
: : : : : : : : : : : : : :   ASM_0 > 0.09:
: : : : : : : : : : : : : : : ...area_seg <= 4.16: campo (2)
: : : : : : : : : : : : : : :   area_seg > 4.16: silvicultura (3/1)
r_v_a <= 1.163:
...contr_135 <= 8.289:
: ...verde <= 91.933:
: : ...area_seg <= 3032.86: sombra (19.3)
: :   area_seg > 3032.86: água (14)
: : verde > 91.933:
: : : ...area_seg > 1572.66: água cinza (3)
: : :   area_seg <= 1572.66:
: : : : ...r_v_a <= 0.991: solo exposto (12/1)

```

```

:      r_v_a > 0.991: campo (2)
contr_135 > 8.289:
...r_ivp_v > 1.624:
...area_seg > 428.04: campo (125/2)
: area_seg <= 428.04:
: ...MDE > 32.66:
:   ...MDE > 44.654:
:     ...ASM_45 > 0.132: sombra (3)
:     : ASM_45 <= 0.132:
:     :   ...MDE <= 63.776: silvicultura (8/1)
:     :   : MDE > 63.776: mata nativa (2)
:     :   MDE <= 44.654:
:     :   ...r_v_a <= 0.962:
:     :     ...IVP > 168.909: banhado (2)
:     :     : IVP <= 168.909:
:     :     :   ...r_ivp_a <= 1.977:
:     :     :     ...MDE <= 38.459: água (3)
:     :     :     : MDE > 38.459: sombra (3)
:     :     :     : r_ivp_a > 1.977:
:     :     :     :   ...azul <= 55.771: mata nativa (2.1)
:     :     :     :     azul > 55.771: campo (2)
:     :     :   r_v_a > 0.962:
:     :     :     ...azul <= 88.155:
:     :     :     :   ...r_ivp_a > 2.462: mata nativa (5/1)
:     :     :     :     r_ivp_a <= 2.462:
:     :     :     :     :   ...r_ivp_v <= 2.087: macrófita (5.2/0.2)
:     :     :     :     :     r_ivp_v > 2.087: campo (5.2/0.2)
:     :     :     :   azul > 88.155:
:     :     :     :     ...r_v_a > 1.144: mata nativa (2)
:     :     :     :     : r_v_a <= 1.144:
:     :     :     :     :     ...corr_0 > 0.1: campo (47/2)
:     :     :     :     :     : corr_0 <= 0.1:
:     :     :     :     :     :     ...ASM_45 <= 0.13: campo (3)
:     :     :     :     :     :     : ASM_45 > 0.13:
:     :     :     :     :     :     :     ...MDE <= 35.914: pastagem (2)
:     :     :     :     :     :     :     : MDE > 35.914: mata nativa (2)
:     :     :     :   MDE <= 32.66:
:     :     :     :     ...MDE <= 28.254:
:     :     :     :     :   ...MDE <= 21.265:
:     :     :     :     :     :   ...ASM_90 <= 0.084: campo (2)
:     :     :     :     :     :     : ASM_90 > 0.084:
:     :     :     :     :     :     :     ...r_ivp_v <= 2.017: macrófita (5/1)
:     :     :     :     :     :     :     : r_ivp_v > 2.017: mata nativa (4/1)
:     :     :     :     :     :     :   MDE > 21.265:
:     :     :     :     :     :     :     ...r_v_a <= 1.078:
:     :     :     :     :     :     :     :   ...r_v_a <= 0.743:
:     :     :     :     :     :     :     :     :   ...IVP <= 117.787: sombra (2)
:     :     :     :     :     :     :     :     :     : IVP > 117.787: solo exposto (2/1)
:     :     :     :     :     :     :     :     :     :   r_v_a > 0.743:
:     :     :     :     :     :     :     :     :     :     ...verde <= 134.137: banhado (137/16)
:     :     :     :     :     :     :     :     :     :     : verde > 134.137: mata nativa (2/1)
:     :     :     :     :     :     :     :   r_v_a > 1.078:
:     :     :     :     :     :     :     :     ...r_ivp_a > 2.285: mata nativa (5/1)
:     :     :     :     :     :     :     :     : r_ivp_a <= 2.285:
:     :     :     :     :     :     :     :     :     ...contr_135 > 12.92:
:     :     :     :     :     :     :     :     :     :     :   ...r_ivp_v <= 1.786: banhado (7/1)
:     :     :     :     :     :     :     :     :     :     :     : r_ivp_v > 1.786: campo (5/1)
:     :     :     :     :     :     :     :     :     :     :     :     contr_135 <= 12.92:
:     :     :     :     :     :     :     :     :     :     :     :     :   ...ind_form > 2.803: pastagem (4)
:     :     :     :     :     :     :     :     :     :     :     :     :     ind_form <= 2.803:
:     :     :     :     :     :     :     :     :     :     :     :     :     :   ...entr_0 <= 1.053: campo (7)
:     :     :     :     :     :     :     :     :     :     :     :     :     :     entr_0 > 1.053: pastagem (3/1)
:     :     :     :   MDE > 28.254:
:     :     :     :     ...azul <= 81.822:
:     :     :     :     :   ...corr_135 <= -0.064: solo úmido (21/3)
:     :     :     :     :     : corr_135 > -0.064: sombra (2)
:     :     :     :     : azul > 81.822:
:     :     :     :     :     ...ASM_45 <= 0.128:
:     :     :     :     :     :   ...r_ivp_a > 2.045: campo (2/1)
:     :     :     :     :     :     : r_ivp_a <= 2.045:
:     :     :     :     :     :     :     ...area_seg <= 1.84: banhado (11)
:     :     :     :     :     :     :     : area_seg > 1.84:
:     :     :     :     :     :     :     :     :   ...corr_135 <= -0.28: campo (2)
:     :     :     :     :     :     :     :     :     : corr_135 > -0.28: banhado (3)
:     :     :     :     :     :     :   ASM_45 > 0.128:
:     :     :     :     :     :     :     ...verde > 127.477:

```

