



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

LUIS FERNANDO CHIMELO RUIZ

PROPOSTA DE CLASSIFICAÇÃO E DE PÓS-CLASSIFICAÇÃO BASEADA EM
OBJETOS DA COBERTURA E DO USO DA TERRA POR MEIO DE IMAGENS OBTIDAS
POR VEÍCULO AÉREO NÃO TRIPULADO

PORTO ALEGRE

2019

LUIS FERNANDO CHIMELO RUIZ

PROPOSTA DE CLASSIFICAÇÃO E DE PÓS-CLASSIFICAÇÃO BASEADA EM
OBJETOS DA COBERTURA E DO USO DA TERRA POR MEIO DE IMAGENS
OBTIDAS POR VEÍCULO AÉREO NÃO TRIPULADO

Tese de doutorado apresentada como
requisito parcial para obtenção do Título
de Doutor em Sensoriamento Remoto.

Universidade Federal do Rio Grande do Sul
Programa de Pós-Graduação em Sensoriamento Remoto

Orientador: Laurindo Antonio Guasselli

PORTO ALEGRE

2019

CIP - Catalogação na Publicação

Chimelo Ruiz, Luis Fernando
Proposta de classificação e de pós-classificação
baseada em objetos da cobertura e do uso da terra por
meio de imagens obtidas por Veículo Aéreo Não
Tripulado (VANT) / Luis Fernando Chimelo Ruiz. --
2019.
83 f.
Orientador: Lurindo Antonio Guasselli.

Tese (Doutorado) -- Universidade Federal do Rio
Grande do Sul, Centro Estadual de Pesquisas em
Sensoriamento Remoto e Meteorologia, Programa de
Pós-Graduação em Sensoriamento Remoto, Porto Alegre,
BR-RS, 2019.

1. Análise de Imagens Baseada em Objetos. 2.
Veículo Aéreo Não Tripulado. 3. Aprendizagem de
máquina. 4. Pós-classificação baseada em objetos. 5.
Cobertura e uso da terra. I. Guasselli, Lurindo
Antonio, orient. II. Título.

TESE

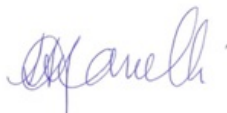
Submetida como parte dos requisitos
para obtenção do Grau de

DOCTOR EM SENSORIAMENTO REMOTO

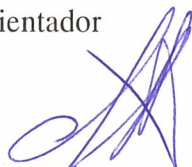
Programa de Pós-Graduação em Sensoriamento Remoto (PPGSR)
Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPRSM)
Universidade Federal do Rio Grande do Sul (UFRGS)
Porto Alegre, RS, Brasil.

Aprovada em : 15/02/2019
Pela Banca Examinadora:

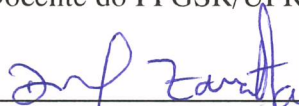
Homologada em: __/__/____
Por:



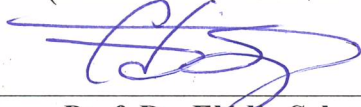
Prof. Dr. Laurindo Antonio Guasselli
Orientador



Prof. Dr. Cristiano Lima Hackmann
(Docente do PPGSR/UFRGS)



Prof. Dr. Daniel Capella Zanotta
(Docente do PPGSR/IFRS)



Prof. Dr. Elédio Sebem
(IFSC)



Prof. Dr. Tatiana Silva da Silva
Coordenadora do Programa de
Pós-Graduação em Sensoriamento
Remoto

Prof^a Tatiana S. da Silva
Coordenadora
Programa de Pós-Graduação em Sensoriamento Remoto
UFRGS

AGRADECIMENTOS

À CAPES pela bolsa de estudo em nível de pós-graduação.

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

Aos funcionários do Programa de Pós-Graduação em Sensoriamento Remoto.

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

Ao pessoal do Laboratório de Geoprocessamento em Análise Ambiental (LAGAM) pelas conversas, pelos cafés, pelos churrascos e pela amizade.

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

Aos meus sobrinhos e afilhados pelos momentos ímpares.

À Eliane Teixeira, *in memoriam*, pela amizade e pelas risadas.

Aos meus pais, Antonio e Irene, que sempre acreditaram em mim e fizeram tudo que estava ao seu alcance para que eu alcançasse esse objetivo.

À minha esposa, Tatiana Teixeira, pelo companheirismo, pela compreensão nas horas que faltei e pelo incentivo nos momentos difíceis.

Seria uma atitude ingênua esperar que as classes dominantes desenvolvessem uma forma de educação que proporcionasse às classes dominadas perceber as injustiças sociais de maneira crítica.

Paulo Freire

RESUMO

Uma das principais aplicações das imagens de sensoriamento remoto é a classificação da cobertura e do uso da terra. Para mapeamentos mais detalhados, utilizam-se atualmente imagens aéreas obtidas por Veículo Aéreo Não Tripulado (VANT). No entanto, essas imagens apresentam uma alta variabilidade espectral intraclasse e entreclasses, dificultando a classificação da cobertura e do uso da terra. A partir dessas considerações, esta tese tem como objetivos: (i) desenvolver e avaliar um método de reconhecimento de padrões não paramétrico para classificação baseada em objetos da cobertura e do uso da terra, denominado de *Iterative K – Nearest Neighbors Algorithm* (IKNN); (ii) propor e avaliar dois métodos de pós-classificação que consideram o contexto dos objetos, intitulados como: Votação dos Objetos Vizinhos (VOV) e Quantificação das Fronteiras dos Objetos (QFO); e (iii) desenvolver uma ferramenta automatizada para classificação baseada em objetos que integre reconhecimento de padrões e Análise de Imagens Baseada em Objetos, chamada de GeoPatterns. Foi utilizada uma ortoimagem aérea obtida por um Veículo Aéreo Não Tripulado (VANT) Echar 20B. Essa ortoimagem foi segmentada utilizando o método crescimento de regiões. As ferramentas e os métodos propostos foram desenvolvidos utilizando a linguagem de programação Python e as bibliotecas: Scikit-Learn (mineração de dados), Numpy (computação científica) e PyQGIS (integra Python e QGIS). O método IKNN possibilitou a seleção das características mais relevantes e o tratamento da sobreposição dos seus valores. Quando utilizado um limiar de confiança igual a 60%, IKNN resultou em uma Proporção Correta (PC) igual a 90,0%, o que foi superior aos métodos *Support Vector Machine* (SVM) e *k – Nearest Neighbors* (k-NN). O método de pós-classificação baseada em objetos, VOV, aumentou a acurácia da classificação de 92,5% para 95,7%, quando avaliados objetos da segmentação maiores que 7000 pixels. O método de pós-classificação QFO obteve resultados superiores, alcançando acurácias iguais a 97,0% para objetos da classificação maiores que 9400 pixels. O programa GeoPatterns viabilizou a integração de técnicas não paramétricas de reconhecimento de padrões e OBIA, assim como automatizou os processos de segmentação, amostragem e classificação dos objetos. A interface gráfica tornou mais acessível a classificação baseada em objetos da cobertura e do uso da terra por meio de imagens com resolução espacial submétrica obtidas por VANT.

Palavras-chave: mineração de dados, aprendizagem de máquina, classificação baseada em objetos.

ABSTRACT

One of the main applications of remote sensing images is both land cover and land use classifications. For more refined mapping, Unmanned Aerial Vehicle (UAV) aerial images are currently used. However, these images show both high intraclass and interclasses spectral variability, making it difficult to achieve land cover and land use classifications. Based on these considerations, this thesis aims: both to develop and to evaluate a nonparametric pattern recognition method for object-based land cover and land use classification, which is called Iterative K - Nearest Neighbors Algorithm (IKNN); both to propose and to evaluate two post-classification methods that consider the objects' context, Voting Neighbors Objects (VNO) and Quantification of Object Frontiers (QOF); and to develop an automated tool for object-based classification that integrates recognition patterns and Object-Based Image Analysis, called GeoPatterns. To do so, an aerial orthoimage was obtained by an Unmanned Aerial Vehicle (UAV) Echar 20B. This orthoimage was segmented by using region growing method. Both proposed tools and methods were developed by using Python programming language and Scikit-Learn (data mining), Numpy (scientific computing) and PyQGIS (which integrate Python and QGIS) libraries. The IKNN method allowed the selection of the most relevant characteristics and the treatment of the overlapping of its values. To the 60% confidence threshold, IKNN method resulted in a Correct Proportion equal to 90.0%, which was superior to the Support Vector Machine (SVM) and k-Nearest Neighbors (k-NN) methods. The VNO object-based post-classification method increased the accuracy of the classification from 92.5% to 95.7% in the evaluation of 7,000 pixels or higher segmentation objects. The QOF post-classification method obtained higher results, reaching up to 97.0% for 9,400 pixels or higher objects classification. The GeoPatterns program enabled the integration of both non-parametric recognition patterns and OBIA techniques, as well as it has automated the segmentation, the sampling and the classification of objects. By using UAV-obtained sub-metric resolution images, the graphical interface made both land cover and land use object-based classification more accessible.

Keywords: data mining, machine learning, object-based Classification

LISTA DE ILUSTRAÇÕES

Figura 1 – Veículos Aéreos Não Tripulados (VANT)	16
Figura 2 – Classificação baseada em objetos.....	18
Figura 3 – Pós-classificação baseada em objetos	20

SUMÁRIO

1 ASPECTOS INTRODUTÓRIOS.....	11
1.1 Introdução.....	11
1.2 Objetivos.....	13
1.2.1 Objetivo geral.....	13
1.2.2 Objetivos específicos.....	13
1.3 Hipótese.....	13
2 REFERENCIAL TEÓRICO-METODOLÓGICO.....	14
2.1 Imagens de sensoriamento remoto obtidas por Veículo Aéreo Não Tripulado (VANT)	14
2.2 Classificação e pós-classificação baseada em objetos da cobertura e do uso da terra...	17
3 RESULTADOS APRESENTADOS NA FORMA DE ARTIGOS CIENTÍFICOS.....	22
3.1 Artigo 1: Algoritmo <i>Iterative K – Nearest Neighbors</i> (IKNN) para classificação de imagens com resolução espacial submétrica obtidas por Veículo Aéreo Não Tripulado (VANT).....	22
3.2 Artigo 2: Métodos de Pós-classificação baseado em objetos da cobertura e do uso da terra por meio de imagens com resolução espacial submétrica obtidas por Veículo Aéreo Não Tripulado (VANT).....	38
3.3 Artigo 3: GeoPatterns: Reconhecimento de Padrões e Análise de Imagens Baseada em Objetos (OBIA).....	54
4 CONCLUSÕES GERAIS.....	74
REFERÊNCIAS.....	77

LISTA DE ABREVIATURAS E SIGLAS

DA - Desacordo de Alocação
DQ - Desacordo de Quantidade
GI - *Gini Importances*
GDAL - *Geospatial Data Abstraction Library*
GNSS - *Global Navigation Satellite System*
INPE - Instituto Nacional de Pesquisas Espaciais
IMU - *Inertial Measurement Unit*
IKNN - *Iterative K – Nearest Neighbors Algorithm*
k-NN - *k – Nearest Neighbors Algorithm*
LIDAR - *Light Detection And Ranging*
ND - nível digital
OBIA - *Object-Based Image Analysis*
PC - Proporção Correta
QFO - Quantificação das Fronteiras dos Objetos
RF - *Random Forest*
SVM - *Support Vector Machine*
SfM - *Structure from Motion*
TMO - Tamanho Mínimo do Objeto
VOV - Votação dos Objetos Vizinhos
VBO - Votação Baseada em Objetos
VANT - Veículo Aéreo Não Tripulado

ESTRUTURA DA TESE

A tese “Proposta de classificação e de pós-classificação baseada em objetos da cobertura e do uso da terra por meio de imagens obtidas por Veículo Aéreo Não Tripulado” foi estruturada no formato de artigos científicos e está organizada em quatro capítulos.

O capítulo 1 aborda aspectos introdutórios e contempla a introdução, os objetivos e a hipótese. O capítulo 2 apresenta o referencial teórico-metodológico, considerando os seguintes itens: imagens de sensoriamento remoto obtidas por Veículo Aéreo Não Tripulado (VANT), classificação e pós-classificação baseada em objetos da cobertura e do uso da terra. O Capítulo 3 abrange os três artigos científicos apresentados a seguir. O capítulo 4 apresenta as conclusões obtidas pela pesquisa.

- Artigo 1 desenvolve e avalia um método de reconhecimento de padrões não paramétrico denominado de *Iterative K – Nearest Neighbors Algorithm* (IKNN). Esse método explora as limitações do *k – Nearest Neighbors Algorithm* (k-NN) e trata a alta dimensionalidade dos dados e a sobreposição dos valores das características utilizando uma árvore de decisão. O número de k vizinhos mais próximos é selecionado por intermédio de um algoritmo iterativo. Além disso, avalia o melhor caso do método IKNN com SVM e a k-NN;

- Artigo 2 apresenta dois métodos de pós-classificação que consideram o contexto espacial dos objetos: Votação dos Objetos Vizinhos (VOV) e Quantificação das Fronteiras dos Objetos (QFO). VOV considera a segmentação e a classificação baseada em objetos. O método analisa objetos com áreas menores que um limiar preestabelecido pelo usuário, conta as classes dos objetos vizinhos, e a classe mais votada é atribuída ao objeto analisado. O QFO considera apenas a classificação baseada em objetos. Os objetos com áreas menores que um limiar preestabelecido pelo usuário são selecionados, o perímetro dos objetos vizinhos são quantificados, e o objeto analisado recebe a classe do objeto vizinho com maior perímetro de fronteira;

- Artigo 3 propõe o programa GeoPatterns, uma ferramenta desenvolvida na linguagem de programação Python 3 para ser utilizada como *plugin* no Sistema de Informação Geográfica QGIS3. GeoPatterns contempla as etapas de segmentação, de amostragem e de classificação baseada em objetos. Como método de segmentação, foi utilizado o crescimento de regiões disponível no GRASS-GIS. A amostragem possibilita o cálculo de várias estatísticas básicas, como média, desvio-padrão, máximo, mínimo. A classificação baseada em objetos pode ser realizada com os métodos *Random Forest* e k-NN.

1 ASPECTOS INTRODUTÓRIOS

1.1 Introdução

A classificação da cobertura e do uso da terra é um dos principais propósitos do sensoriamento remoto. Antes da minituarização dos sistemas inerciais, do Sistema de Posicionamento por Satélite, dos pilotos automáticos e dos sensores, que possibilitaram o desenvolvimento dos Veículos Aéreos Não Tripulados (VANT) de baixo custo, mapeamentos da cobertura e do uso da terra com resolução espacial submétrica eram custosos e escassos, dificultando o avanço científico em diferentes áreas do conhecimento. Na agricultura, as imagens obtidas por VANT contemplam dois aspectos fundamentais: resolução espacial submétrica e altíssima resolução temporal, proporcionando o monitoramento de áreas agrícolas (XIANG & TIAN, 2011) e a identificação de ervas-daninhas (LOTTE et al., 2017).

A classificação da cobertura e do uso da terra em imagens com resolução espacial submétrica obtidas por VANT contemplam etapas de pré-processamento, extração das características, redução da dimensionalidade, classificação e pós-processamento. O pré-processamento consiste em formar regiões homogêneas (objetos geográficos) por meio da segmentação ou da clusterização da imagem, proporcionando a Análise de Imagens Baseada em Objetos (*Object-Based Image Analysis – OBIA*) (LALIBERTE et al., 2011).

A unidade de processamento da OBIA são os objetos geográficos e não os pixels isolados (BLASCHKE et al., 2014). A classificação baseada em objetos tem resultado em acurácias superiores para imagens com resolução espacial submétrica, quando comparado com a classificação baseada em pixel. A classificação baseada em pixel é afetada pela alta variabilidade espectral dos alvos, que é característico dessas imagens (PANDE-CHHETRI et al., 2017).

A extração das características consiste em calcular estatísticas básicas das bandas e das texturas da imagem para os objetos geográficos, como extrair características geométricas e contextuais desses objetos geográficos. O conjunto de dados resultante é de alta dimensionalidade e, devido a isso, são utilizadas técnicas para selecionar as características mais relevantes, que reduzem a dimensionalidade dos dados, selecionando características mais informativas (CROMMELINCK et al., 2016).

Uma forma eficiente de reduzir a dimensionalidade dos dados é por meio da construção de uma Árvore de Decisão ou de um comitê (*ensemble*). Laliberte, Browning & Rango (2012) avaliaram técnicas de distância de Jeffreys-Matusita, análise de árvore de decisão e otimização do espaço das características para reduzir a dimensionalidade dos dados em uma classificação da

cobertura e do uso da terra de imagens obtidas por VANT. Os autores relataram que a técnica por árvore de decisão foi a mais adequada. Puissant, Rougier & Stumpf (2014) utilizaram a técnica de aprendizagem por comitê (*ensemble*), *Random Forest*, para reduzir a dimensionalidade do conjunto de dados e classificar a vegetação em áreas urbanas de uma imagem com altíssima resolução espacial.

Métodos não paramétricos de reconhecimento de padrões são os mais utilizados na classificação da cobertura e do uso da terra por meio de imagens com resolução espacial submétrica. Pande-Chhetri et al. (2017) avaliaram métodos de classificação multirresoluções para áreas úmidas, considerando os modelos Máquina Vetores Suporte, Rede Neural Artificial e Máxima Verossimilhança. Os autores argumentam que a classificação menos acurada foi obtida pela Máxima Verossimilhança, um modelo paramétrico de reconhecimento de padrões que considera a distribuição das amostras como gaussiana. Contudo, essa afirmação nem sempre é verdadeira, uma vez que as imagens com resolução espacial submétrica apresentam uma alta variabilidade espectral. Ahmed et al. (2017) conseguiram uma acurácia global de até 95,0% na classificação de espécies de vegetação utilizando o método *Random Forest* em imagens multiespectrais obtidas por VANT.

Christiansen et al. (2014) utilizaram imagens térmicas obtidas com altitudes entre 3 e 10 m e o classificador *k-Nearest Neighbor* (k-NN) para detectar animais na vida selvagem, alcançando acurácias próximas a 93,0%. O método k-NN apresenta vantagens em relação à facilidade na sua implementação e à simplicidade no seu entendimento. Suas desvantagens estão ligadas ao número de vizinhos (k) utilizados na classificação, pois baixos valores de k estão propensos a ruído, e altos valores de k podem incluir amostras de classes distintas (OOI, NG & LIM, 2013). Outra limitação do método está na dificuldade em lidar com conjunto de dados de alta dimensionalidade e correlacionados (SAMANIEGO & SCHULZ, 2009; CÁNOVAS-GARCÍA & ALONSO-SARRÍA, 2015).

A etapa de pós-processamento, também denominada como pós-classificação, é a menos abordada no mapeamento da cobertura e do uso da terra por meio de imagens com resolução espacial submétrica. A pós-classificação consiste em refinar as classes de uma imagem classificada para aumentar sua acurácia (HUANG, DAVIS & TOWNSHEND, 2002).

Estudos têm considerado a classificação baseada em pixel na pós-classificação da cobertura e do uso da terra por meio de imagens com resolução espacial submétrica. Akar (2017) aplicou uma filtragem majoritária em uma classificação baseada em pixel e aumentou a acurácia em torno de 3,0%. No entanto, a classificação baseada em pixel tem resultado em mapeamentos menos acurados para imagens com resolução espacial submétrica. Assim, desenvolver métodos de pós-classificação baseada em objetos pode ser uma alternativa mais eficiente. Pande-Chhetri et al. (2017) obtiveram

alta acurácia ao refinar uma classificação baseada em objeto utilizando informações temáticas e contextuais das classes.

A implementação dessas etapas metodológicas da OBIA e do reconhecimento de padrões com técnicas não paramétricas tem sido desenvolvidas, em sua maioria, em programas comerciais, como o eCognition (LALIBERTE, BROWNING & RANGO, 2012; HELLESEN; MATIKAINEN, 2013). Programas gratuitos possibilitam a elaboração de apenas parte da metodologia, obrigando os geocientistas a utilizarem vários programas para obterem uma classificação baseada em objeto por meio de imagens com resolução espacial submétrica. Em muitos estudos, foi verificada a dificuldade em avaliar os diversos parâmetros que compõem tanto a etapa de segmentação quanto a de classificação (QIAN et al., 2014; TEODORO & ARAÚJO, 2014). Um programa automatizado que possibilitasse a execução dessas etapas metodológicas facilitaria os estudos dependentes da OBIA e das técnicas não paramétricas de reconhecimento de padrões.

1.2 Objetivos

1.2.1 Objetivo geral

Desenvolver e avaliar métodos de classificação e de pós-classificação da cobertura e do uso da terra por meio de imagens com resolução espacial submétricas obtidas por Veículo Aéreo Não Tripulado (VANT).

1.2.2 Objetivos específicos

(i) propor e avaliar um método de classificação não paramétrico de reconhecimento de padrões, denominado *Iterative K – Nearest Neighbors Algorithm* (IKNN), propondo melhorias nas limitações do método *k-Nearest Neighbor* (k-NN);

(ii) desenvolver e avaliar dois métodos de pós-classificação baseado em objetos: Quantificação das Fronteiras dos Objetos e Votação dos Objetos Vizinhos; e

(iii) desenvolver uma ferramenta que integre classificação não paramétrica de reconhecimento de padrões e OBIA, intitulado de GeoPatterns, contemplando as etapas de segmentação, amostragem e classificação baseada em objetos.

1.3 Hipótese

Técnicas não paramétricas de reconhecimento de padrões e Análise de Imagens Baseada em Objetos possibilitam mapeamentos mais acurados da cobertura e do uso da terra por meio de imagens com resolução espacial submétrica obtidas por VANT.

2 REFERENCIAL TEÓRICO-METODOLÓGICO

2.1 Imagens de sensoriamento remoto obtidas por Veículo Aéreo Não Tripulado (VANT)

A crescente demanda por mapeamentos em escalas mais refinadas impulsionaram os avanços tecnológicos na engenharia aeroespacial e proporcionaram maior oferta de imagens de sensoriamento remoto com altíssima resolução espacial (BELWARD & SKØIEN, 2015). Satélites como WorldView, GeoEye, QuickBird, IKONOS, SuperView adquirem imagens com resolução espacial maior que um metro, contribuindo, por exemplo, para estudos relacionados às áreas urbanas (HADAVAND et al., 2016), como na discriminação da vegetação a nível de espécie (LALIBERTE, BROWNING & RANGO, 2012).

Imagens aéreas obtidas por VANT tornaram possíveis mapeamentos ainda mais refinados, com resoluções espaciais na casa dos centímetros. Feng et al., (2015) utilizaram ortoimagens com resolução espacial submétrica (20 cm) obtidas por VANT para mapear uma inundação em Yuyao, China. Luna & Lobo (2016) mapearam falhas de 23,5 cm em uma plantação de cana-de-açúcar por meio de ortoimagens com resolução espacial subdecimétrica (4,7 cm) coletadas por VANT.

Dentre os VANT utilizados em pesquisas na área de sensoriamento remoto, estão os multirrotores, os helicópteros, as asas fixas e os dirigíveis (Figura 1). A seleção é realizada conforme a finalidade da pesquisa e o orçamento disponível (YANG et al., 2017).

Os multirrotores apresentam vantagens devido ao baixo custo, à capacidade de pairar, à decolagem e aterrissagem na vertical, que em alguns casos são automáticos. No entanto, suas limitações estão no curto tempo de voo, na baixa carga útil e na dependência das condições climáticas (TURNER, LUCIEER & WATSON, 2012). Helicópteros também decolam e aterrissam na vertical, pairam e voam para os lados, com uma carga útil maior que os multirrotores (CHAPMAN et al., 2014). Suas dificuldades estão no alto custo de manutenção, na complexidade da operação e na intensidade do ruído que limita algumas aplicações.

Os VANT de asas fixas possibilitam voos em velocidades mais rápidas, bem como um maior tempo de voo. Entretanto, são equipamentos mais caros, que exigem certa habilidade na pilotagem, também podem capturar imagens de menor qualidade devido à velocidade e à altitude do voo (FENG et al., 2015; LALIBERTE, BROWNING & RANGO, 2012). Dirigíveis são capazes de flutuar, carregar mais sensores, decolar e aterrissar na vertical, porém, são lentos e instáveis, dificultando a obtenção de informações precisas (LIEBISCH et al., 2015).





	Multirrotor	Helicóptero	Asa fixa	Dirigível
				
Modelo	DJIS1000+	AXH-E230	Bat-3	CB3000
Custo	Baixo	Médio	Médio	Alto
Carga útil (kg)	7	15	9	10
Velocidade (m/s)	12	23	33	15
Tempo de voo(min)	15	48	3600	7200
Altitude(m)	500	3000	3000	120

Figura 1 - Veículos Aéreos Não Tripulados (VANT)

Fonte: Adaptado de Yang et al. (2017).

A qualidade da ortorretificação das imagens obtidas pelo VANT é altamente influenciada pelas condições ambientais, como o ângulo e a intensidade da iluminação, bem como pelos procedimentos nos processamentos dessas imagens. Kedzierski & Wierzbicki (2015) desenvolveram e avaliaram um índice de qualidade que traduz o número de pontos de amarração utilizados no mosaico em relação à qualidade radiométrica das imagens. Os autores concluíram que dias com céu claro ou ligeiramente nublado e com uma grande intensidade de luz resultaram em maior número de pontos de amarração e maior precisão da ortoimagem.

Uma etapa crucial no fluxo de trabalho da ortorretificação é o processamento geométrico, que consiste na determinação das características internas do sensor (orientação interior), da orientação exterior (posição e rotação do sensor durante a coleta das imagens) e do modelo utilizado para encontrar a relação geométrica entre o objeto e o valor do nível digital (ND) registrado (PÁDUA et al., 2017).

Técnicas modernas de computação visual, como *Structure from Motion* (SfM), e algoritmos de fotogrametria podem fornecer soluções eficazes e de baixo custo na ortorretificação dessas imagens, uma vez que não necessitam de sensores inerciais (*Inertial Measurement Unit* - IMU) e coordenadas espaciais (*Global Navigation Satellite System* – GNSS) com alta precisão. SfM possibilita um processamento com alta fidelidade geométrica do ajuste do feixe, baseando-se na pose da câmera para determinar a posição e a orientação do sensor. Esse método está disponível em vários programas gratuitos, como MicMac e VisualSFM, e comerciais, como Pix4D e Agisoft Photoscan. Algumas desvantagens dessa abordagem estão relacionadas ao alto custo computacional, exigindo tempo e hardwares sofisticados, como no planejamento do voo, já que é necessária uma alta sobreposição entre faixas e entre imagens (AASEN et al., 2018).

Fraser & Congalton (2018) avaliaram os programas PhotoScan e Pix4D no processamento de imagens obtidas por VANT em ambientes florestais complexos. Para os autores, o PhotoScan gerou saídas mais completas, aumentou a densidade de alinhamentos entre as imagens e obteve uma

ortoimagem com maior resolução espacial. No entanto, foi muito custoso quando configurado para processar as imagens com uma qualidade média.

A construção do modelo 3D da superfície obtida por SfM-fotogrametria é inicialmente capturada em um sistema de referência arbitrário. A georreferência desse modelo 3D pode ser realizada diretamente utilizando orientações externas conhecidas das imagens (georreferenciamento direto) ou fornecendo pontos de controle que são reconhecíveis nas imagens (georreferenciamento indireto). O georreferenciamento direto requer a medição das coordenadas da câmara no exato momento em que a imagem é adquirida, o que é um desafio, porque o VANT está em movimento, muitas vezes, com uma velocidade de vários metros por segundo, dificultando a sincronização do disparo da câmara com a frequência de amostragem do receptor GNSS (HARWIN & LUCIEER, 2012). Outro problema está na precisão dos sensores, geralmente, são de baixo custo e pouco precisos. Georreferenciamento direto com sensores de baixo custo alcança precisões menores que 2 m, como observado no estudo de Turner, Lucieer & Watson (2012), que obtiveram uma precisão de 1,25m para uma ortoimagem com resolução espacial de 1 cm.

Sanz-Ablanedo et al. (2018) avaliaram o georreferenciamento indireto em uma ortoimagem obtida com VANT, numa área com altitudes entre 990 m e 1548 m, gerando imagens com resoluções espaciais entre 2,7 cm e 11 cm. A frequência de imagens para cada local foi maior que 9. Os autores relataram que a precisão horizontal foi de, em média, 5 vezes maior que a resolução espacial da imagem. Já a precisão vertical foi de 2,5 vezes maior que a horizontal. Para aumentar as precisões, foi recomendado a utilização de 3 pontos de controle a cada 100 imagens.

2.2 Classificação e pós-classificação baseada em objetos da cobertura e do uso da terra

Na OBIA são identificadas duas etapas principais: a segmentação da imagem e a classificação baseada em objetos, conforme Figura 2. Na etapa de segmentação, os métodos de crescimento de regiões têm sido mais utilizados. A segmentação por crescimento de regiões inicia gerando pixels sementes aleatórios sobre a imagem, posteriormente, são avaliadas as similaridades dos pixels sementes com seus vizinhos. Pixels com similaridades menores que um limiar preestabelecido pelo usuário são agrupados, gerando as regiões (objetos) similares. A segmentação também reduz o campo de análise, o número de objetos gerados sempre será menor que o número de pixels de uma imagem (ESPINDOLA et al., 2006).

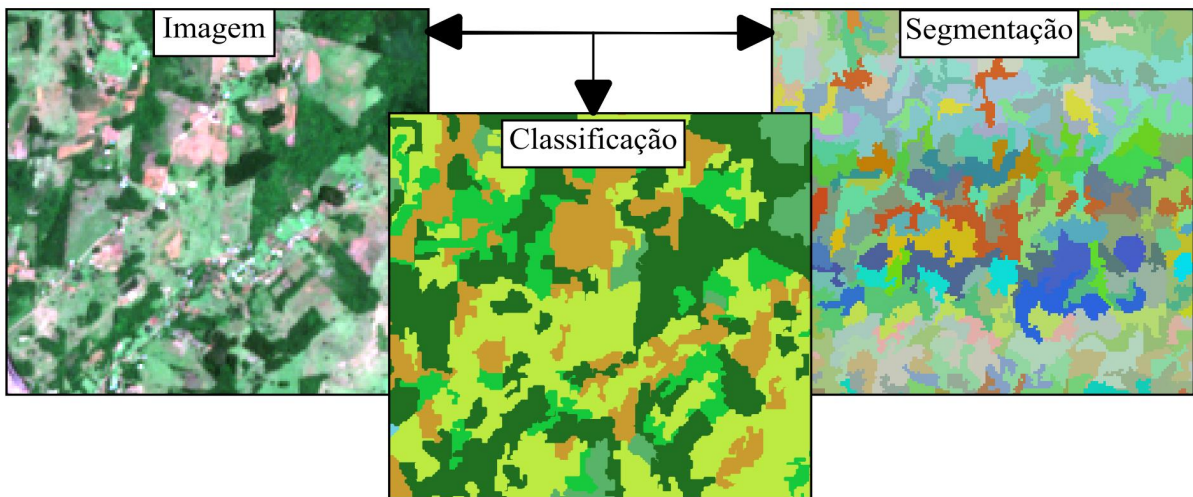


Figura 2 - Classificação baseada em objetos.

Fonte: Autor

Segmentação por crescimento de regiões é um processo iterativo, controlado pelo número máximo de iterações. Os pixels sementes utilizados na primeira iteração podem ser informados pelos usuários. Parâmetros que controlam o tamanho dos objetos também são considerados e estão diretamente relacionados com a acurácia da classificação, uma vez que a sobressegmentação apresenta várias classes para o mesmo objeto, e a subsegmentação gera vários objetos para a mesma classe.

Ma et al. (2015) avaliaram a escala da segmentação (tamanho dos objetos) na classificação baseada em objetos de uma imagem obtida por VANT. Observaram um decréscimo na acurácia global para valores de escala acima de 110, altos valores geraram objetos híbridos, ou seja, representando mais de uma classe. Ma et al. (2017), revisando trabalhos sobre classificação baseada em objetos, identificaram uma correlação negativa entre os parâmetros ótimos da escala da segmentação e a resolução espacial das imagens.

Com a segmentação, as características das bandas podem ser amostradas, originando o conjunto de dados utilizado na classificação. Essas características podem ser formadas pelas bandas da imagem, texturas e índices espectrais, considerando características geométricas e contextuais dos objetos. Estatísticas básicas, como média e desvio-padrão, podem ser calculadas para as bandas das imagens. Já para as características geométricas são consideradas a área, o perímetro, a forma do objeto, entre outros. Características contextuais dos objetos são menos comuns no mapeamento da cobertura e do uso da terra, entretanto, o conceito geral é avaliar a similaridade dos objetos com seus vizinhos (LALIBERTE & RANGO, 2011).

Todas essas características extraídas geram um conjunto de dados com alta dimensionalidade, apresentando características correlacionadas e pouco informativas. Métodos de

mineração de dados ou reconhecimento de padrões com técnicas não paramétricas possibilitam a seleção das características mais relevantes, não exigem que as características tenham uma distribuição normal e resultam em acuradas classificações baseadas em objetos da cobertura e do uso da terra por meio de imagens obtidas por VANT.

Métodos paramétricos têm resultado em mapeamentos menos acurados, esses métodos baseiam sua decisão por meio de estatísticas básicas extraídas das características, como média e matriz de covariância (PHIRI & MORGENROTH, 2017). A premissa fundamental é em relação à normalidade dessas características, mas essa condição nem sempre é verdadeira em características geradas mediante imagens obtidas por VANT. Feng et al. (2015) avaliaram o método paramétrico Máxima Verosimilhança e o método não paramétrico *Random Forest* no mapeamento da vegetação em áreas urbanas. Os autores comentaram que algumas texturas não apresentaram uma distribuição normal, resultando em acurácias mais baixas para o método Máxima Verosimilhança.

Ma et al. (2015) consideraram adequada a integração do método não paramétrico *Random Forest* e OBIA na classificação de áreas agrícolas em imagens obtidas por VANT. OBIA obteve bom desempenho no delineamento dos alvos, e *Random Forest* possibilitou a seleção de características relevantes e uma acurada classificação baseada em objetos. Li et al. (2016) compararam métodos na classificação baseada em objetos de áreas agrícolas e relataram que SVM e *Random Forest* são mais sensíveis à escala da segmentação. Árvore de Decisão e *Random Forest* foram os métodos mais apropriados para a seleção das características. Chabot et al. (2018) utilizaram *Random Forest* e OBIA, obtendo uma acurácia global superior a 90% na classificação de espécies de vegetação aquáticas emergentes e submersas em águas rasas, por meio de imagens multiespectrais obtidas por VANT. Sibaruddin et al. (2018) avaliaram a classificação baseada em objetos em áreas urbanas utilizando imagens obtidas pelo VANT Sensefly e obtiveram acurácias superiores a 80% para os classificadores *Support Vector Machine* (SVM) e *Random Forest*. Os autores também concluíram que os métodos *Random Forest* e *k-Nearest Neighbor* (k-NN) são menos sensíveis ao aumento das amostras de treinamento.

Pande-Chhetri et al. (2017) comentaram as dificuldades encontradas na classificação de áreas úmidas: grande diversidade de espécies que apresentam resposta espectral semelhante, influência da lâmina de água e difícil acesso. Mesmo com esse cenário, os autores aplicaram classificação baseada em objetos em áreas úmidas e obtiveram acurácias superiores a 70% por meio de uma ortoimagem com resolução espacial de 8-30 cm coletada por VANT.

Todos os processos envolvidos na classificação baseada em objetos influenciam na acurácia do mapeamento, como a determinação do limiar de similaridade e do tamanho dos objetos na etapa de segmentação, bem como os ajustes dos parâmetros dos métodos de classificação. Programas

automatizados e gratuitos que integrassem técnicas não paramétricas de reconhecimento de padrões e OBIA facilitariam a avaliação desses parâmetros, como a utilização desses métodos pelos geocientistas. Ma et al. (2017) avaliaram 254 estudos envolvendo OBIA e áreas úmidas, os autores comentaram que quase 90% das pesquisas foram realizadas com os programas comerciais eCognition, ENVI e ERDAS.

A etapa de pós-classificação tem como objetivo refinar uma classificação para melhorar seu desempenho. Na Figura 3, está apresentada a pós-classificação proposta por Tarabalka et al. (2008), que consiste em aplicar a classificação baseada em pixel, segmentar a imagem e contabilizar os pixels classificados para cada objeto da segmentação. As classes mais votadas (mais frequente) são atribuídas aos objetos.

Imagens obtidas por VANT são de altíssima resolução espacial, com pixels na casa dos decímetros ou dos centímetros, apresentando uma alta variabilidade espectral que dificulta uma acurada classificação baseada em pixel. Hadavand et al. (2016), com objetivo de classificar características hiperespectrais em áreas urbanas, relatam que a classificação baseada em objetos foi superior em média 8% quando comparada com classificação baseada em pixels. Assim, métodos de pós-classificação para imagens com resolução espacial submétrica poderiam apresentar acurácias mais elevadas utilizando como unidade básica os objetos e não os pixels.

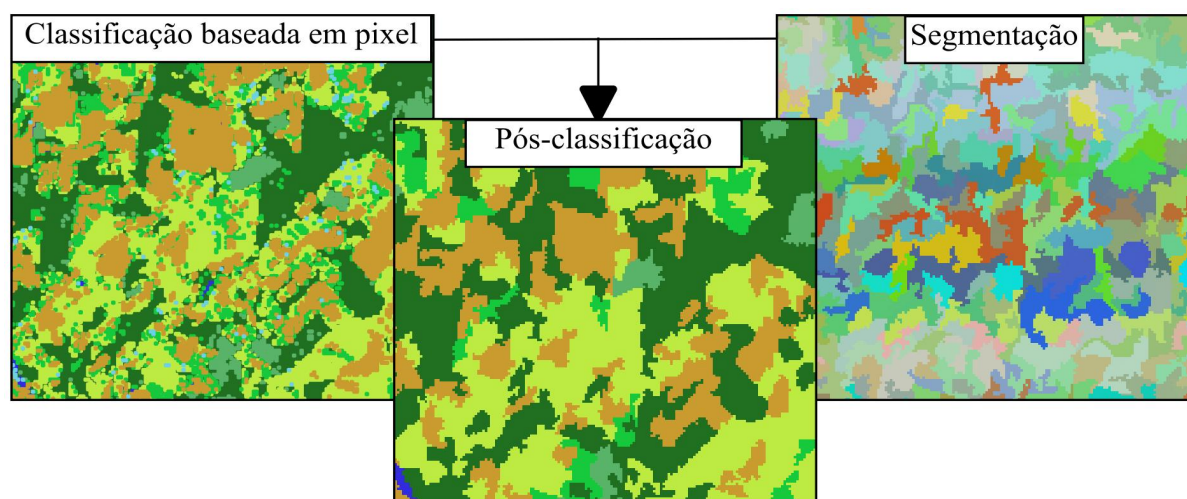


Figura 3 - Pós-classificação baseada em objetos.

Fonte: Autor

A validação dos mapeamentos é extraída da matriz confusão, também conhecida como matriz do erro ou matriz de contingência. Cohen (1960) propôs o índice kappa para calcular o erro da classificação por meio da matriz de confusão. No entanto, Pontius (2000) relata que, quando a proporção correta for menor que a proporção correta esperada ao caso, o kappa recebe valores

negativos, e seu uso não seria recomendado para área de sensoriamento remoto. Pontius & Millone (2011) apresentam os índices de validação, Proporção Correta (PC), Desacordo de Alocação (DA) e Desacordo de Quantidade (DQ), que podem substituir o kappa. O processo começa gerando a matriz de confusão em relação aos dados de referência com a classificação, posteriormente é estimada a matriz populacional. Com a posse da matriz populacional, calcula-se os índices, conforme as Equações (1), (2) e (3).

$$PC = \sum_{j=1}^J D_{jj} \quad (1)$$

Em que: PC é a proporção correta; J é o número total de classes; j é a coluna estimada da matriz populacional e D_{jj} é matriz diagonal da matriz populacional.

$$DQ = \frac{\sum_{g=1}^J q_g}{2} \quad (2)$$

Em que: DQ é discordância de quantidade global incorporando todas as classes; J é o número total de classes; q_g é a discordância de quantidade para uma classe arbitrária g .

$$DA = \frac{\sum_{g=1}^J a_g}{2} \quad (3)$$

Em que: DA é a discordância de alocação global incorporando todas as classes; J é número total de classes; a_g é a discordância de alocação para uma classe arbitrárias g .

3 RESULTADOS APRESENTADOS NA FORMA DE ARTIGOS CIENTÍFICOS

3.1 Artigo 1: Algoritmo *Iterative K – Nearest Neighbors* (IKNN) para classificação de imagens com resolução espacial submétrica obtidas por Veículo Aéreo Não Tripulado (VANT)

RESUMO

Este estudo propõe uma técnica de classificação denominada *Iterative K – Nearest Neighbors* (IKNN) para imagens com resolução espacial submétrica adquiridas por Veículos Aéreos Não Tripulados (VANT). O método é baseado no desenvolvimento de soluções simples para algumas limitações encontradas no algoritmo tradicional k - *Nearest Neighbors* (k -NN). As principais mudanças em relação ao tradicional são: (i) lidar com a alta dimensionalidade dos dados e a sobreposição das características através do cálculo do *Gini Importances* (GI) e (ii) selecionar o número de k vizinhos por meio de um algoritmo iterativo de acordo com a taxa de acerto da classificação em cada iteração. Considerando os índices GI como pesos das características, o método IKNN alcançou uma redução razoável na dimensionalidade dos dados e tratou a sobreposição entre as características. Experimentos utilizando o método proposto com limiar de confiança igual a 60% resultaram em uma proporção correta (PC) de 90%, o que foi superior em comparação aos métodos *Support Vector Machine* (SVM) e o tradicional k -NN.

Palavras-chave: classificação baseada em objetos, cobertura e uso da terra, mineração de dados



Iterative K – Nearest Neighbors Algorithm (IKNN) for submeter spatial resolution image classification obtained by Unmanned Aerial Vehicle (UAV)

Luis Fernando Chimelo Ruiz^a, Laurindo Antonio Guasselli^a, Alexandre ten Caten^b and Daniel Capella Zanotta^c

^aRemote Sensing, Federal University Rio Grande of Sul, Porto Alegre, Brazil; ^bDepartment of Biodiversity, Agriculture and Forestry, Federal University of Santa Catarina, Curitibanos, Brazil; ^cDepartment of Geoprocessing, Federal Institute of Education, Science and Technology of Rio Grande do Sul, Rio Grande, Brazil

ABSTRACT

This study proposes a classification technique named Iterative K – Nearest Neighbors algorithm (IKNN) for submeter spatial resolution images acquired by Unmanned Aerial Vehicles (UAV). The method is based on the development of simple solutions for some limitations found in the traditional K – Nearest Neighbors algorithm (KNN). The main changes with respect to the traditional one are: (i) handle the high dimensionality of the data and the overlapping of the features by computing Gini Importances (GI); and (ii) selecting the number of KNN through an iterative algorithm according each classification rate at each iteration. Considering the GI indices as features weights, the IKNN method achieved a reasonable reduction in dimensionality of the data and overlapping among features. Experiments using the proposed method with confidence threshold equal to 60% resulted in a proportion correct (PC) of 90%, which was superior comparing to Support Vector Machine (SVM) and simple KNN methods.



ARTICLE HISTORY

Received 6 October 2016
Accepted 8 February 2018

1. Introduction

Very high spatial resolution aerial image data are being increasingly used in studies requiring fine detail, such as urban mapping and recognition of complex targets. Cameras onboard Unmanned Aerial Vehicles (UAV) can be used to obtain very high spatial resolution or sub-meter images. Due to the high radiometric heterogeneity presented by targets in these images, land cover classification from data provided by UAV is considered a challenge task (Lechner et al. 2012; Janalipour and Mohammadzadeh 2016).

To overcome this drawback, the use of Object-Based Image Analysis (OBIA) along with non-parametric classification techniques, such as Decision Trees (DT), Artificial Neural Networks (ANN) or Support Vector Machines (SVM) has been tested in some studies achieving suitable results (Laliberte and Rango 2011). OBIA aims to generate regions (or objects) formed by pixels with similar characteristics, reducing the number of elements analyzed and increasing the number of available features (Blaschke 2010). Furthermore,

CONTACT Luis Fernando Chimelo Ruiz  ruiz.ch@gmail.com  Remote Sensing, Federal University Rio Grande of Sul, Avenue Bento Gonçalves, Nº 9500, District Agronomia, Porto Alegre, Brazil

© 2018 Informa UK Limited, trading as Taylor & Francis Group

non-parametric classification methods like Decision Trees allows selection of the most important features (Heumann 2011; Hellesen and Matikainen 2013).

Laliberte, Fredrickson, and Rango (2012) evaluated three methods for selecting the most informative features in OBIA considering simplicity of use and accuracy improvement after selection of input features. The Gini Importance (GI), commonly used in Decision Trees, showed more adequacy considering the evaluation criteria. As reported by Cánovas-García and Alonso-Sarriá (2015) the GI was also the best feature selection method among the evaluated techniques.

Classification techniques such as SVM, ANN, DT and K -Nearest Neighbors (KNN) are usually used in very high spatial resolution images due to their ability to adjust to the most particular characteristics of the training samples. However, SVM and ANN require complex adjustments and are very sensitive to the tuning parameters (Song, Duan, and Jiang 2012; Qian et al. 2015), whereas DT generates parallel decision rules regarding input features and is not a proper technique for high dimensional data sets (Pal and Mather 2003). On the other hand, KNN does not establish a rigid separation between features (Budreski et al. 2007) and is less sensitive to the classification parameters (Qian et al. 2015). The KNN classification technique is also known for its simplicity and intuitiveness, making it easy to understand how it proceeds (Ooi, Ng, and Lim 2013). However, the performance of KNN method has limitations due to the dependence of the nearest neighbors (K), since small values of K are more sensitive to noise, but large values for K can comprise elements from other classes. There are also limitations concerning the overlapping of features among classes and metrics to calculate the nearest neighbors (Samaniego and Schulz 2009), as well as the high dimensionality of the data (feature space) (Cánovas-García and Alonso-Sarriá 2015).

The present work aims to develop a methodology to overcome the limitations of the KNN classification technique to produce more accurate classification results in very high spatial resolution images provided by UAV. The main contributions of this work are (i) reducing the space and overlapping of features by assigning weights to the features through GI; and (ii) selecting the number of K nearest neighbors through an iterative procedure considering the success rate of classification at each iteration.

2. Dataset and methods

Figure 1 shows a workflow of the methodological stages used in this work. First, the steps of the IKNN algorithm are developed, and then, the dataset used to evaluate the algorithm is presented.

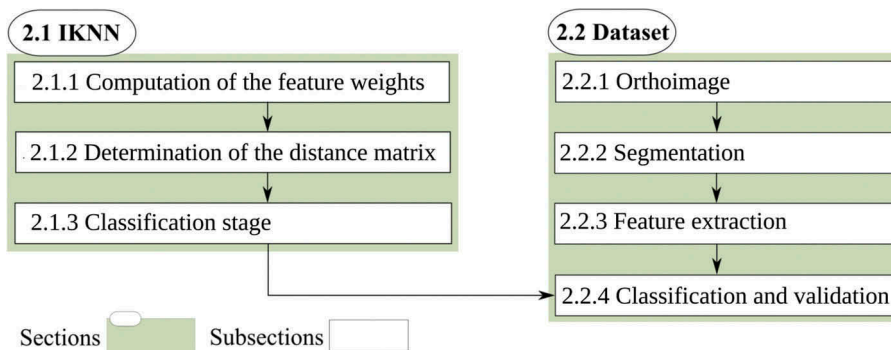


Figure 1. Methodological stages.

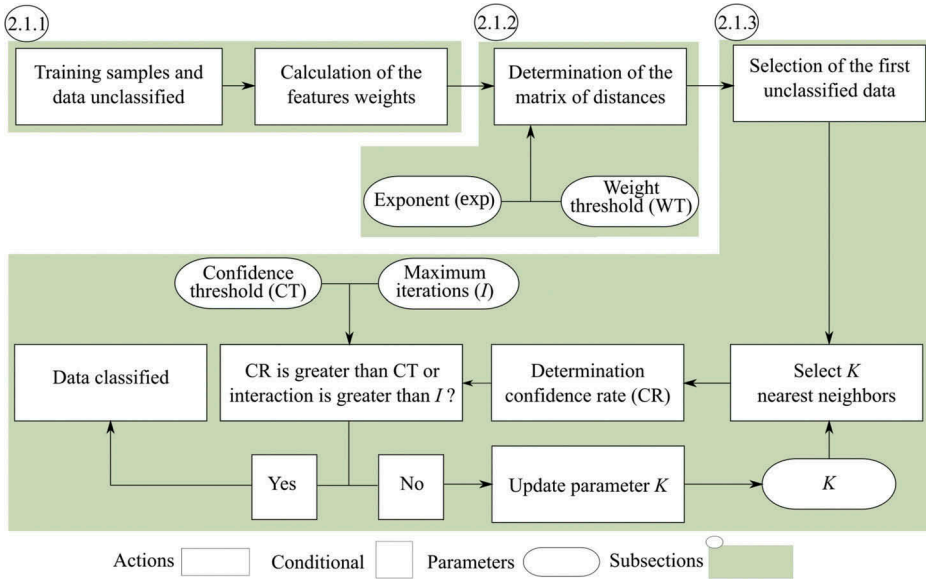


Figure 2. Flowchart of the IKNN algorithm.

2.1. Iterative k – nearest neighbors algorithm (IKNN)

The flowchart of the proposed method is illustrated in the diagram of Figure 2. For sake of simplicity, the steps were split in the sub-sections 2.1.1, 2.1.2 and 2.1.3.

2.1.1. Computation of the features weights

When different weights for each feature are computed, the overlapping of values and the reduced relevance of correlated features can be handle. Gini Importance (GI) derived from a DT structure was used to compute the weights. To this end, in this study we employed the Classification and Regression Tree (CART) algorithm from (Laliberte, Fredrickson, and Rango 2012) and Gini impurity criteria from (Menze et al. 2009; Mureriwa et al. 2016). DT is a binary model constructed by dividing the input dataset into increasingly homogeneous nodes, then minimizing the impurity of subsequent nodes (child nodes). The DT production starts by selecting the root node of the tree and definition of the Gini index (Equation 1) of the target classes, followed by computation of the Gini index for the features.

$$G(\tau) = 1 - p_0^2 - p_1^2 \quad (1)$$

For a set of classes $\Omega(\omega_k)_{k=0}^c$, where k represents the classes and c is the total number of classes in the problem at each node (τ) within a DT, p_0 and p_1 are the probabilities of the classes $\{k = 0, k = 1\}$:

$$p = \frac{m_k}{m} \quad (2)$$

where m_k is the number of samples of the k classes, assuming $k = 0$ or $k = 1$, and m is the total number of samples in node τ .

As the Gini index is computed before and after the division of the nodes, the feature value that minimizes the impurity is selected as the root node of the tree. For the remaining nodes (child nodes), the same procedures are performed. In Equation 3 it is presented the calculation of the Gini impurity (ΔI).

$$\Delta I = G(\tau) - p_l G(\tau_l) - p_r G(\tau_r) \quad (3)$$

In Equation (3), ΔI quantifies how much the value of the Gini index decreased after the division (Gini impurity); $G(\tau)$ is the value of the Gini index for the node before the division; p_r is the probability of the classes for the right node (τ_r), p_l is the probability of the classes for the left node (τ_l); $G(\tau_r)$ is the value of the Gini index for the right node (τ_r); and $G(\tau_l)$ is the value of the Gini index for the left node (τ_l).

After the production of the tree, a measure defined as importance of feature (θ) is obtained by adding the value of reduction presented by the Gini impurity of each node. Since only one feature θ is selected at each node, the most frequent feature is the one which has caused more reduction in the Gini impurity, which is able to produce the higher value of the Gini Importance (GI). The estimation of GI importance is performed by Equation (4) (Menze et al. 2009).

$$GI(\theta) = \sum_{DT} \sum_{\tau} \Delta I_{\theta}(\tau, DT) \quad (4)$$

where GI is the sum of the Gini impurity (ΔI) obtained from the feature θ in each node τ of the tree (DT).

The values of GI are normalized to a range between 0 and 1 by dividing the value of each predictive GI feature by the sum of their values (Mururiwa et al. 2016), making possible the interpretation of the importance of the features and making easy its use as weight in the definition of the distance matrix.

2.1.2. Determination of the distance matrix

The distance matrix allows us to understand the proximity of each sample to the unlabeled data. The total number of matrix rows is equal to the number of unlabeled data, as well as the number of columns is equal to the number of training samples. In this paper, we used the Minkowski metric of variant distances, given by Equation (5). Mayanka (2013) evaluated the KNN method with the Mahalanobis, Diagonal Mahalanobis and Minkowski metrics for classification of remote sensing data. The author obtained more accurate classifications results using the Minkowski metric.

$$d(\mathbf{x}, \mathbf{y}) = \left(\sum_{a=1}^t w_a |x_a - y_a|^{\text{exp}} \right)^{1/\text{exp}} \quad (5)$$

In the above relation, d is the distance; \mathbf{x} is the vector of features of training samples; \mathbf{y} is the vector of features of unlabeled data; t is total features; w is the weight relative to the importance of the feature, which was computed by GI. When exp is equal to 1, the distance type is called Manhattan and for exp equal to 2 the distance is called Euclidean (Ooi, Ng, and Lim 2013).

In order to select different values of weights it was defined the Weight Threshold (WT). WT controls the removal of less importance features in the calculation of the matrix of distances, then one can exclude features which obtained low GI values (Figure 2). It has also been defined in the algorithm when the WT results in zero, all features and their respective weights will be considered. On the other hand, when the value of the WT is equal to one, all the features have the same weight in the estimation of the distances. They evaluated the values 0.00; 0.01; 0.02; 0.03; 0.04 and 0.05 for the WT parameters. For the parameter exp, the values analyzed were 1 (Manhattan), 2 (Euclidean) and 3 (Minkowski).

2.1.3. Classification stage

The classification of the data will be iterative on the distance matrix. The algorithm selects the first row of the matrix, which corresponds to the distances of training samples for the first data unlabeled (i). In the next step, the algorithm selects the number (K_i) of nearest neighbors of i and computes the Confidence Rate (CR $_i$) (Figure 2), the initial value of K_i is defined by the user. The algorithm evaluates whether the confidence rate is higher than a Confidence Threshold (CT) initially set. If the confidence rate is higher, the data is classified; otherwise the value of K_i is only updated. Since the confidence rate cannot reach the CT preset by the user, the algorithm has a user defined constraint that defines the maximum number of iterations (l) (Figure 2).

Since the goal of updating K is to retrieve to the next iteration a higher confidence rate than CT, then in the next iteration the value of the most common class (F_{n+1}) divided by the next value of K (K_{n+1}) should be greater than CT (Equation 6):

$$\frac{F_{n+1}}{K_{n+1}} \geq CT \quad (6)$$

Where n is the value of the current iteration; (F_{n+1}) is the frequency value of the class with the largest number of nearest neighbors in the next iteration; and K_{n+1} is the number of nearest neighbors for the next iteration.

K_{n+1} can be defined as the subtraction of the number of K nearest neighbors of the current iteration (K_n) with the value of the most frequent class of the current iteration (F_n), added to the most frequent class value of the next iteration (F_{n+1}), according to Equation (7).

$$K_{n+1} = (K_n - F_n) + F_{n+1} \quad (7)$$

Inserting K_{n+1} from Equation (7) in Equation (6), as show in Equation (8):

$$\frac{F_{n+1}}{(K_n - F_n) + F_{n+1}} \geq CT \quad (8)$$

By solving Inequality (8) to F_{n+1} , as illustrated in Equation (9):

$$F_{n+1} \geq \frac{CT(K_n - F_n)}{1 - CT} \quad (9)$$

The Inequality (9) can define what should be the frequency of the most frequent class in the next iteration (F_{n+1}). By inserting this result in Equation (7), one can define the number of K nearest neighbors to be considered in the next iteration (K_{n+1}).

Figure 3 depicts an example of the proposed algorithm for the maximum number of iterations (l) equal to 3, Confidence Threshold (CT) equivalent to 70%, and the initial value of K (number of neighbors) equal to 3 neighbors (K_{n+1}). Parameter l is the maximum number of iterations which IKNN method has to reach the Confidence Threshold (CT). In the first iteration (Figure 3(a)), the unlabeled data was evaluated against three nearest neighbors (Figure 3(d)), in which the most frequent class was class A, and confidence rate (CR_{+1}) to the first iteration was 66.6%. Since it did not reach CT of 70%, the algorithm performs a new iteration with a new value for K . K_{+2} in the next iteration was computed by Equation (7), and resulted in 5. This function has been developed to force the next iteration achieved a confidence rate for the most frequent class greater than the predetermined threshold.

To the second iteration 5 nearest neighbors were selected (Figure 3(e)), and the most frequent class registered was B. If the two new nearest neighbors were the class A, the confidence rate would exceed the CT and the unlabeled data would be classified as A. However, class B had the highest frequency and resulted in a confidence rate of 60%. Since it did not exceed the value of CT, K_{+3} is updated by Equation (7), resulting in seven (Figure 3(b)).

Since it is the last iteration (maximum number of iterations (l) is 3). In the case of the confidence rate does not exceed the CT, the unlabeled data is classified according to the iteration showing the high confidence rate. In the third iteration, the algorithm selects seven (K_{+3}) nearest neighbors (Figure 3(f)). In this turn, the new 2 nearest neighbors are the most frequent class of the previous iteration, so it is expected that the accuracy rate

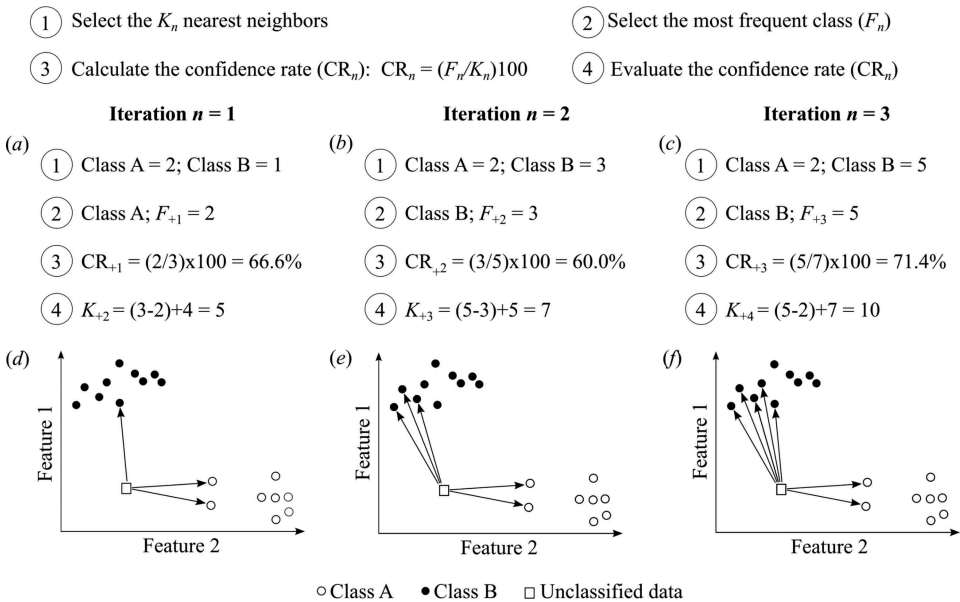


Figure 3. Example of classification algorithm IKNN.

is greater than the predetermined CT. As identified in [Figure 3\(c\)](#), the confidence rate results in 71.4% and the unlabeled data is classified as B. The algorithm was developed in Python 2.7 programming language, with the support of NumPy programming library (Walt, Colbert, and Varoquaux 2011).

2.2. Dataset (experiments)

In this section, we will present the experimental setup used to evaluate the IKNN, SVM and KNN algorithms. For sake of simplicity, [Section 2.2](#) was split into sub-sections [2.2.1](#) Orthoimage, [2.2.2](#) Segmentation, [2.2.3](#) Feature extraction and [2.2.4](#) Classification and validation.

2.2.1. Orthoimage

The images were acquired with the Sony ILCE-7R model camera with a resolution of 36.4 megapixel onboard the UAV echar 20B. The camera captures images in the bands of Near Infrared (NIR – 670–770 nm), blue (370–520 nm) and green (470–570 nm). The flight took place on 21 July 2014, at approximately 13:00 (local time), at the Experimental Station of Federal University of Rio Grande do Sul (UFRGS), in Eldorado do Sul city. The images cover the region defined by the rectangle 30° 5' 9" S, 51° 41' 4" W and 30° 5' 45" S and 51° 40' 31" W. The flight covered an area of 73.15 ha with approximately 80% and 60% overlapping between subsequent images. The data retrieved pixels with spatial resolution of 0.15 m. In order to orthorectify the images, control points collected by Global Position System (GPS) aboard UAV were used in the absolute positioning method.

Since the camera is not metric, geometric calibration was performed before the flight by Agisoft Lens program (Agisoft 2016). With this adjustment, the following parameters were determined: focal length, principal point coordinates and radial distortions for inner orientation of the images.

Image processing was carried out in PhotoScan package (Agisoft 2016). The PhotoScan has an automated flow based on computer vision algorithms. The program steps are as follows: input of auxiliary data (lens calibration, inertial measurement unit and GPS data); alignment of images; optimization of the alignment images; determination of dense point cloud; production of the triangular mesh and orthoimage exporting (Agisoft 2016).

2.2.2. Segmentation

The orthoimaging segmentation was performed using the region growing method available in the Spring package of the National Institute of Space Research (Câmara et al. 1996). In a study by Meinel and Neubert (2004), the segmentation method available in Spring, a free and open source package, was compared to other seven segmentation algorithms from different programs. Spring presented segmentation with quality like eCognition and superior to the others.

This segmentation method starts by labeling each pixel on the image as a distinct region. Then, a similarity decision rule is applied for each neighboring region. To merge two adjacent regions, the similarity between them must be lesser than the user defined threshold and mutually similar. The last step of segmentation is to group regions with size smaller than the minimum value set by the user. In this work, similarity thresholds

evaluated were 1, 2, 5, 10, 15, 20, 30, 40 and 50, and for the minimum size of the region, the values evaluated were 20 and 100 (Teodoro and Araújo 2014). All segmentations results were submitted to the IKNN classification method (subsection 2.2.4) and the segmentation with the highest accuracy was selected.

2.2.3. Features extraction

The OBIA features aim to represent the spectral, textural, contextual and geometric information of the objects (Blaschke 2010). Spectral features describe the reflected radiance of the targets and depend directly on the sensor (camera). Textures describe the spatial arrangements of pixels and are useful in analyzing images with high spatial resolution. Geometry originates from mathematical morphology, representing size and shape of objects. Context considers the boundaries and neighboring objects (Laliberte and Rango 2011). In this work, we used the features described in Table 1.

2.2.4. Classification and validation

Training samples for each target were obtained using regular distributed points. The points were produced with equidistance of 25 meters, resulting a total of 825 points on a regular basis over the entire study area and comprising all the land cover classes, which in this study were: Pasture (PA), Stubble (ST) Wet soil (WS), Meadow (ME), Wetland (WL), Turbid Water (TW) and Water (WA). To validate the classification results, 400 random points were collected. The allocation of classes for these points was made through visual interpretation of the orthoimage. The points were used to select the regions of segmentation and thus produce the training and validation samples.

The weights of the features were estimated by GI by CART model, using the Scikit-Learn library (Pedregosa et al. 2011). Gini impurity was used as dividing criterion and, for maximum depth, the value was equal to 3 (Qian et al. 2015). For classification with IKNN, the following arrangements Confidence Threshold (CT) were assessed: 40%, 50%, 60%, 70%, 80% and 90%. The K values initially considered were 1, 3, 5 and 7. The maximum number of iterations parameter (l) were set to 2, 3, 4, 5, 6, 7, 8, 9, 10 and 15. The best

Table 1. Features.

Feature type	Features	References
Geometrical	compactness; smoothness; rectangularity; density, isometrics; inverse of isometrics (INIS); bulkiness; eccentricity; roundness; circular form factor (CFF) and area.	Goodin, Anibas, and Bezymennyi (2015)
Contextual	mean difference among bands of the object and its neighbors (dif_mean_NIR, dif_mean_green and dif_mean_blue).	Laliberte and Rango (2011).
Spectral	- Estimations of the mean values (mean_blue, mean_green e mean_NIR) and Standard Deviation (SD) (SD_blue, SD_green e SD_NIR) bands of blue, green and near-infrared (NIR). - Ratios between NIR bands with blue (r_NIR_b), green (r_NIR_g) and the ratio of green band with blue (r_g_b).	Laliberte and Rango (2011)
Textural	Extraction of 13 texture features from the co-occurrence matrix of gray levels (Grey Level Cooccurrence Matrix – GLCM): Angular Second Moment (ASM), correlation (corr), entropy (entr), contrast (contr), Sum of Average (SA) Difference of Entropy (DE), Sum of Entropy (SE), Variance (VAR), Inverse Difference Moment (IDM), Difference Variance (DV), Sum Variance (SV), Information Measures of Correlation (IMC) and Maximal Correlation Coefficient (MCC).	Haralick, Shanmugan, and Dinstein (1973), Laliberte and Rango (2009)

case for the proposed method was evaluated for the SVM and KNN. For SVM, the kernel Radial Basis Function (RBF) was evaluated. Thus, we analyzed the following values for cost (C): 10^{-1} , 10^0 , 10^1 , 10^2 , 10^3 , 10^4 , 10^5 , 10^6 , 10^7 and 10^8 , and for gamma (γ): 10^{-5} , 10^{-4} , 10^{-3} , 10^{-2} , 10^{-1} , 10^0 , 10^1 , 10^2 , 10^3 and 10^4 (Qian et al. 2015). Regarding KNN, integer values of K ranging from 1 to 20 were analyzed. Both methods, SVM and KNN, were evaluated using all the features. The classification results obtained by SVM and KNN were performed by Scikit-Learn programming library (Pedregosa et al. 2011). The validations of classifications results were quantified by Proportion Correct (PC), Quantity Disagreement (QD) and Allocation Disagreement (AD) (Pontius and Millones 2011). For the best case of the IKNN classification, the confusion matrix and Producer Accuracy (PRC) were evaluated. PRC indicates the likelihood of a reference pixel to be correctly classified (Congalton 1991).

3. Results and discussion

It was observed that the regions generated with similarity thresholds: 30, 40 and 50, contained more than one class of land cover, preventing the correct discrimination of these classes. Thus, these threshold values were not submitted to IKNN classification.

The highest accuracy was obtained with a similarity threshold of 10 and a minimum region size of 100, resulting in a PC value of 90.0%. These values were used as segmentation parameters in this study.

The lowest accuracy values were obtained by combining the similarity thresholds 1, 2 and 5 with a minimum region size of 20, obtaining PC values lower than 78.0%. This result can be due because low values for these parameters generate many similar regions, preventing precise classification these regions into land cover classes.

The values of importance obtained for features by the GI are illustrated in Figure 4. The two highest values were found for the ratio between green and blue (r_{g_b} - 0.34) and the standard deviation of channel green (SD_green - 0.12), with lower importance

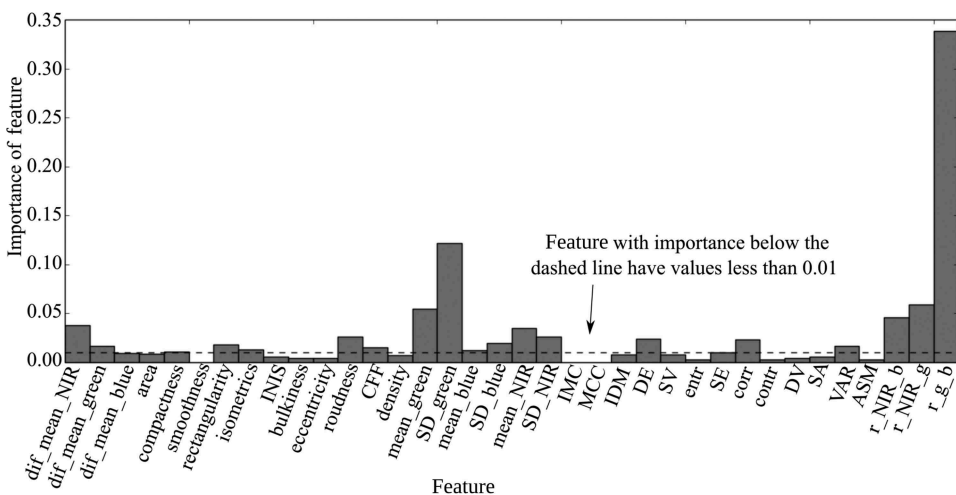


Figure 4. Amounts features importance.

(close to 0.05) for the features generated by the ratio between NIR and green (r_{NIR_g}), and the average of channel green ($\text{mean}_{\text{green}}$). It can be noticed that the spectral features retrieved the highest importance values. Laliberte, Fredrickson, and Rango (2012) also reported in their study that spectral features are more likely to be selected, but different from the present study, the authors found higher amounts for spectral features derived from channel Red.

The remaining features resulted in amounts lower than 0.05 (Figure 4), in which 16 features reached values less than 0.01 (dotted line in Figure 4). These features may be considered less meaningful; they present low power discrimination among land cover classes. Among these 16 features three of them resulted in zero: IMC, MCC and smoothness, reducing about 8% the data dimensionality. Laliberte, Fredrickson, and Rango (2012) obtained reduction of about 80%. Cánovas-García and Alonso-Sarria (2015) also achieved reduction close to 80%. By evaluating the classifications obtained by the authors, it can be identified that in addition to the dimensionality reduction, there was an improvement in the classification accuracies. Another positive point of reduced dimensionality is related to the memory consumption and processing time.

Table 2 shows the values of IKNN algorithm parameters that resulted in the largest PC and lowest QD e AD for different WT values. The two largest PC were 90.0% e 89.2%, which correspond to WT equal to 0.00 and 0.01, respectively. For the WT equal to 0.00, 33 features were considered resulting in a reduction of three features. The WT equal to 0.01 corresponds to 21 features, resulting in a reduction of 41% in the dimensionality of the data. As expected, the largest reduction in the number of features was obtained to the WT equal to 0.05, resulting in 90% of reduction and PC equal to 88.2%. Therefore, it is emphasized that values different of 0 for the parameter WT can be considered in applications with issues concerning memory and processing time, as they provide a further reduction in the dimensionality of the data.

For the parameter exponent, it was observed a higher occurrence of value 1, resulting in faster computations since it means only the difference between the training samples and the unlabeled data. The parameter K registered a higher occurrence of value 7. By initializing this parameter with proper values, the chances of reach CT are increased. The parameter l has achieved values between 5 and 7. CT parameter presented 60% and 70% as more frequent values. This parameter was discussed in Figure 5.

By inspecting Table 2, reducing the number of features causes accuracy decrease. Thus, it is understood that the use of the GI to weight the features is enough to reduce the dimensionality of data and assigning relevance for the features. Then, evaluations are performed with the classification reached with WT equal to 0.00. Figure 5 was produced to understand the behavior of parameters CT and l with WT = 0.00, the exponent equal to 1 and K initially equal to 7. As can be seen in Figure 5, CT equal to

Table 2. Parameters of IKNN algorithm for varied WT.

WT	Total number of features	exponents	K initial	CT(%)	l	PC (%)	AD (%)	QD (%)
0.00	33	1	7	60	7	90.0	5.6	4.4
0.01	21	2	6	70	5	89.2	6.6	4.2
0.02	12	3	5	60	7	88.4	6.1	5.5
0.03	7	1	7	70	6	89.0	6.0	5.0
0.04	5	3	7	70	6	88.7	6.6	4.7
0.05	4	2	3	90	4	88.2	6.0	5.8




Figure 5. PC obtained for different I values and for different confidence thresholds (CT).

40% resulted in PC values almost constant for different entries of I . For CT equal to 50%, the same behavior is observed until $I = 7$, then CT = 50% presented high CP values. These results express that low values of CT (40% and 50%) are less sensitive to the parameter I , since they achieved similar PC for varied values of I . This may be because low CT values allow labeling of the data in the first few iterations. Thus, even if I is large (15), the data is sorted in the first few iterations since they reach the pre-established CT.

Intermediate values of CT, such as 60%, resulted in large PC values up to $I = 10$. For CT equal to 70%, resulting PC were higher until $I = 6$ (Figure 5). This may be caused because intermediate values for CT (60% and 70%) force new iterations and increase the number of K neighbors. But with the increase of I (greater than 7), these intermediate CT values (60% and 70%) consider very distant neighbors and result in reduced accuracies. When the CT parameter received high values, about 80% or 90%, the accuracy was lower than 82%, thus they were not represented in Figure 5. This may be caused because high WT values force the maximum number of iterations, and the number of K nearest neighbors reaches large values. Thus, farthest data and other classes are considered in the classification.

Figure 6(a) shows the orthoimage used in the present study and Figure 6(b) shows its classification result. The results were obtained with the following parameters: WT = 0.00, the exponent equal to 1, the initial $K = 7$, CT equal to 60% and I equal to 7, resulting in PC = 90.0%. The classification result achieved for this study was higher than that found by Laliberte et al. (2011). In their work, the authors used a multispectral sensor coupled in a UAV and the eCognition program to segment the image and the CART algorithm to select the most informative features. The regions were classified using the nearest neighbor method. Based on this methodology, the authors could classify species of pastures with an overall accuracy larger than 83%.

In this work, the SVM method resulted in PC of 88.5%, QD = 6.9% and AD = 4.6%. This result was achieved using RBF kernel (Radial Basis Function), C equal 10 and γ equal 0.00001. High values of C produce overfitting, while the γ parameter changes the form of the hyperplane (Huang, Davis, and Townshend 2002). With these values (C and γ), the SVM method was able to avoid overfitting and could produce an optimal hyperplane in the training samples. For KNN the best accuracy was obtained

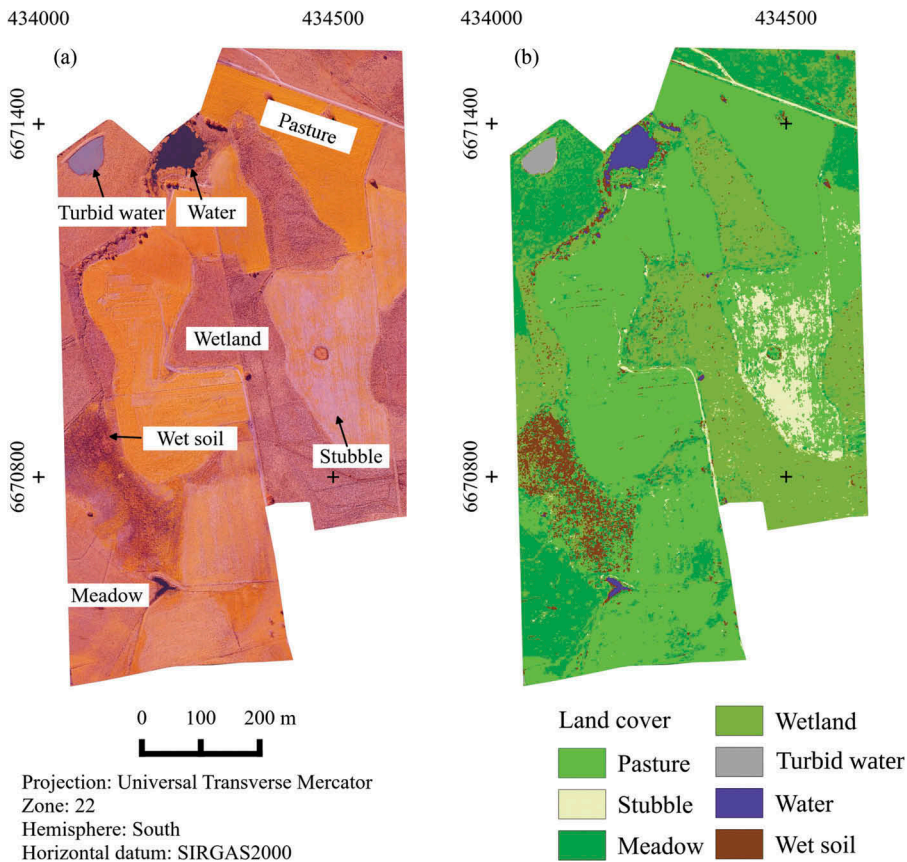


Figure 6. (a) Orthoimage and (b) classification by the IKNN method.

with Manhattan (exponent equal to 1) and $K = 5$, resulting in $PC = 76.2\%$, $QD = 16.3\%$ and $AD = 7.5\%$. Both methods were evaluated for LP equal to 0. Qian et al. (2015) evaluated four classifications in OBIA and also found higher overall accuracies for SVM against KNN.

Assuming the classification methods tested, the IKNN resulted in the highest PC and lowest values of QD and AD . This fact corroborates that the IKNN method provides improved results compared to SVM and classical KNN. Other advantages of IKNN are its simplicity and its adequacy for very large datasets required in OBIA images with sub-meter spatial resolution.

These high classification accuracies found by IKNN method are associated with the possibility of excluding redundant features, allocating smaller amounts of weights to less importance features, and selecting K corresponding to high confidence values.

The classification map (Figure 6(b)) was performed by segmenting the orthoimage (Figure 6(a)). From the 76,826 regions contained in segmentation, 50,818 have been classified in the first iteration, considering only 7 nearest neighbors. The remaining 26,008 regions demanded more iterations and the average number of nearest neighbors was 17. The confidence rates resulted in values close to 54%. In general, the confidence rates resulted in values lower than the defined CT . This is because the algorithm stores

Table 3. Confusion matrix.

		Reference data							User's accuracy (UA) (%)
		PA	ST	ME	WL	TW	WA	WS	
Classification	PA	155	4	7	1	0	0	3	91
	ST	1	34	0	2	0	0	0	92
	ME	5	0	53	1	0	0	2	87
	WL	0	1	9	93	0	0	4	87
	TW	0	0	0	0	3	0	0	100
	WA	0	0	0	0	0	5	0	100
	WS	0	0	0	0	0	0	17	100
Producer's accuracy (PRC) (%)		96	87	77	96	100	100	65	

the confidence rate of each iteration. As stated before, if the value of CT is not reached, the algorithm classifies the data using the iteration with the highest confidence rate. Qian et al. (2015) achieved higher accuracies for K smaller than those found in this study. The authors evaluated different values of K parameter in OBIA with submetric spatial resolution, reaching global accuracies close to 87% for $K = 3$.

Table 3 presents the confusion matrix and Producer Accuracy (PRC), obtained from the comparison of the classification by the IKNN method (Figure 6(b)) with the 400 validation samples (references). Classes with complex spectral behavior, like Turbid Water (TW), Water (WA) and Wetland (WL), were well separated, resulting in high PRC values of 100, 100 and 95.9% respectively.

The class Meadow (ME) comprises the rougher texture, close to Turbid Water class, making this class similar to WL, and in places with lower vegetation, similar to PA. Table 3 depicts this behavior. From the 69 validation samples, 9 were attributed to class WL and 7 were labeled as PA. This difficulty in class discrimination made the EC value only 76.8%.

Class Pasture (PA) presented large spectral differences caused by different stages of its phenological cycle. Even though, the IKNN method reached a PRC equal to 96.3%. The Stubble class (ST), which is formed by remnant vegetation from the last harvest, occurring in places where the pasture is still sprouting, has its class confused with the PA class. This can be verified by analyzing the confusion matrix (Table 3), where from the 39 ST class validation samples, 34 samples were correctly classified and 4 were mislabeled as PA class, resulting in a PRC value equal to 87.2%.

The poorest classification result was obtained for the class Wet soil (WS). This class is a wetland with regrowth vegetation. Such complexity resulted to a low PRC value of 65.4%. From 26 validation samples, 3 were assigned to class PA, 2 to class ME and 4 to WL.

4. Conclusion

This study has proposed an alternative version of the KNN algorithm for very high spatial resolution image classification, called IKNN. The advantages conferred by the suggested technique are the dimensionality reduction of the data by selecting features according to the Gini Importance (GI) and selecting the number of K nearest neighbors through an iterative algorithm. Experiments comparing the proposed method with traditional classification methods showed reasonable gain of accuracy measured by PC.

The selection of GI values higher than zero for weighting features resulted in a dimensionality reduction of 8%, indicating the reflectance in the channel green as the most importance feature. Considering the high accuracies obtained for $WT = 0.00$, it is concluded that the GI was sufficient to determine the relevance of the features and outline their overlapping. Considering the CT parameter in the classification problem, it was found that intermediate values like 60 and 70% resulted in higher accuracies. The explanation lies in the fact that intermediate values for CT force new iterations, thus gradually increasing the number of K nearest neighbors, resulting an optimal number at the convergence. The highest PC was found when WT was 0.00, the exponent equals 1, the initial $K = 7$, $CT = 60\%$ and $I = 7$, resulting in $PC = 90\%$, which was better compared to SVM and simple KNN methods. These parameters can serve as reference for future work.

The method IKNN proved adequacy of the GI in the assignment of weights to features to reduce the data dimensionality and treating the overlapping of available features, and thus, the WT parameter to maximize the reduction of data dimensionality. It was found that high values of WT resulted in low accuracies while causing reduction of dimensionality of the data. Thus, since memory and computational time is critical, it is suggested to use values higher than zero WT . Other positive aspect of IKNN method was the determination of K nearest neighbors iteratively, where the value of K is updated to reach the user defined CT . Thus, the user does not define how many nearest neighbors will be selected, but only determines the value of K in the first iteration, causing the automatic selection of K by the algorithm.

The IKNN method allowed discrimination of classes with complex spectral behavior like Turbid Water (TW), Water (WA) and Wetland (WL), resulting in high PRC values of 100%, 100% and 95.9%, respectively. The class Meadow (ME) comprises the rougher texture, close to Turbid water, very similar to WL, and in places with lower vegetation it resulted very similar to PA, resulting in a PRC equal to 76.8%. The class Pasture (PA) presented large spectral differences caused by different stages of its phenological cycle. Even though, the IKNN method reached a PRC equal to 96.3%. The Stubble class (ST), which is formed by remnant vegetation from harvest, occurring in places where the pasture is still sprouting, presented some confusion with PA class, resulting in a PRC equal to 87.2%. The class Wet soil (WS) is a complex target formed by wetland with regrowth vegetation. Such complexity resulted in a low PRC value of 65.4%.

Future developments of this work can evaluate the IKNN algorithm in hyperspectral images as they present high dimensionality and overlapping values features. Also, other metrics of statistical distance than the Euclidean can be considered. A further modification of the algorithm can lie on the ideal fit for K values, defining a maximum value considering the computational cost.

Disclosure statement

No potential conflict of interest was reported by the authors.

Funding

This work was supported by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior.

References

- Agisoft. 2016 "Support Tutorials." Accessed 13 April 2016. <http://www.agisoft.com/support/tutorials/intermediate-level/>.
- Blaschke, T. 2010. "Object Based Image Analysis for Remote Sensing." *Journal of Photogrammetry and Remote Sensing* 65 (1): 2–16. doi:10.1016/j.isprsjprs.2009.06.004.
- Budreski, K. A., R. H. Wynne, J. O. Browder, and J. B. Campbell. 2007. "Comparison of Segment and Pixel-Based Non-Parametric Land Cover Classification in the Brazilian Amazon Using Multitemporal Landsat TM/ETM Imagery." *Photogrammetric Engineering & Remote Sensing, Bethesda* 73 (7): 813–827. doi:10.14358/PERS.73.7.813.
- Câmara, G., R. C. M. Souza, U. M. Freitas, and J. Garrido. 1996. "SPRING: Integrating Remote Sensing and GIS by Object-Oriented Data Modelling." *Computers and Graphics* 20 (3): 395–403. doi:10.1016/0097-8493(96)00008-8.
- Cánovas-García, F., and F. Alonso-Sarría. 2015. "Optimal Combination of Classification Algorithms and Feature Ranking Methods for Object-Based Classification of Submeter Resolution Z/I-Imaging DMC Imagery." *Remote Sensing* 7 (1): 4651–4677. doi:10.3390/rs70404651.
- Congalton, R. G. 1991. "A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data." *Remote Sensing of Environment* 37 (1): 35–46. doi:10.1016/0034-4257(91)90048-B.
- Goodin, D. G., K. L. Anibas, and M. Bezymennyi. 2015. "Mapping Land Cover and Land Use from Object-Based Classification: An Example from a Complex Agricultural Landscape." *International Journal of Remote Sensing* 36 (18): 4702–4723. doi:10.1080/01431161.2015.1088674.
- Haralick, R. M., K. Shanmugan, and I. Dinstein. 1973. "Textural Features for Image Classification." *IEEE Transactions on Systems, Man, and Cybernetics* 3 (6): 610–621. doi:10.1109/TSMC.1973.4309314.
- Hellesen, T., and L. Matikainen. 2013. "An Object-Based Approach for Mapping Shrub and Tree Cover on Grassland Habitats by Use of LIDAR and CIR Orthoimages." *Remote Sensing* 5 (2): 558–583. doi:10.3390/rs5020558.
- Heumann, B. W. 2011. "An Object-Based Classification of Mangroves Using a Hybrid Decision Tree—Support Vector Machine Approach." *Remote Sensing* 3 (11): 2440–2460. doi:10.3390/rs3112440.
- Huang, C., L. S. Davis, and J. R. G. Townshend. 2002. "An Assessment of Support Vector Machines for Land Cover Classification." *International Journal Remote Sensing* 23 (4): 725–749. doi:10.1080/01431160110040323.
- Janalipour, M., and A. Mohammadzadeh. 2016. "Building Damage Detection Using Object-Based Image Analysis and ANFIS from High-Resolution Image (Case Study: BAM Earthquake, Iran)." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9 (5): 1937–1945. doi:10.1109/JSTARS.2015.2458582.
- Laliberte, A. S., and A. Rango. 2011. "Image Processing and Classification Procedures for Analysis of Sub - Decimeter Imagery Acquired with an Unmanned Aircraft over Arid Rangelands." *GIScience & Remote Sensing* 48 (1): 4–23. doi:10.2747/1548-1603.48.1.4.
- Laliberte, A. S., E. L. Fredrickson, and A. Rango. 2012. "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* 15 (2): 70–78. doi:10.1016/j.jag.2011.05.011.
- Laliberte, A. S., M. A. Goforth, C. M. Steele, and A. Rango. 2011. "Multispectral Remote Sensing from Unmanned Aircraft: Image Processing Workflows and Applications for Rangeland Environments." *Remote Sensing* 3 (11): 2529–2551. doi:10.3390/rs3112529.
- Laliberte, A. S., and A. Rango. 2009. "Texture and Scale in Object-based Analysis of Subdecimeter Resolution Unmanned Aerial Vehicle (UAV) Imagery." *IEEE Transactions on Geoscience and Remote Sensing* 47 (3): 761–770. doi:10.1109/TGRS.2008.2009355.
- Lechner, A. M., A. Fletcher, K. Johansen, and P. Erskine. 2012. "Characterising Upland Swamps Using Object-Based Classification Methods And Hyper-Spatial Resolution Imagery Derived From An Unmanned Aerial Vehicle." *Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXII, Melbourne, September*, 101–106.

- Mayanka, B. K. 2013. "Classification of Remote Sensing Data Using K-NN Method." *Journal of Information, Knowledge and Research in Electronics and Communication Engineering* 2 (2): 817–821.
- Meinel, G., and M. Neubert. 2004. "A Comparison of Segmentation Programs for High Resolution Remote Sensing Data." In *Proceedings of 20th ISPRS Congress, Istanbul*.
- Menze, B. H., B. M. Kelm, R. Masuch, U. Himmelreich, P. Bachert, W. Petrich, and F. A. Hamprecht. 2009. "A Comparison of Random Forest and Its Gini Importance with Standard Chemometric Methods for the Feature Selection and Classification of Spectral Data". *BMC Bioinformatics* 10 (1). doi:10.1186/1471-2105-10-213.
- Mureriwa, N., E. Adam, A. Sahu, and S. Tesfamichael. 2016. "Examining the Spectral Separability of *Prosopis Glandulosa* from Co-Existent Species Using Field Spectral Measurement and Guided Regularized Random Forest." *Remote Sensing* 8 (2): 144–160. doi:10.3390/rs8020144.
- Ooi, H. L., S. C.S. C. Ng, and E. Lim. 2013. "ANO Detection with K-Nearest Neighbor Using Minkowski Distance." *International Journal of Signal Processing Systems* 1 (2): 208–211. doi:10.12720/ijsp.1.2.208-211.
- Pal, M., and P. M. Mather. 2003. "An Assessment of the Effectiveness of Decision Tree Methods for Land Cover Classification." *Remote Sensing of Environment* 86 (4): 554–565. doi:10.1016/S0034-4257(03)00132-9.
- Pedregosa, F., G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, et al. 2011. "Scikit-Learn: Machine Learning in Python." *Journal of Machine Learning Research* 12: 2825–2830. <http://www.jmlr.org/papers/volume12/pedregosa11a/pedregosa11a.pdf>.
- Pontius, R. G. J., and M. Millones. 2011. "Death to Kappa: Birth of Quantity Disagreement and Allocation Disagreement for Accuracy Assessment." *International Journal of Remote Sensing* 32 (15): 4407–4429. doi:10.1080/01431161.2011.552923.
- Qian, Y., W. Zhou, J. Yan, W. Li, and L. Han. 2015. "Comparing Machine Learning Classifiers for Object-Based Land Cover Classification Using Very High Resolution Imagery." *Remote Sensing* 7 (1): 153–168. doi:10.3390/rs70100153.
- Samaniego, L., and K. Schulz. 2009. "Supervised Classification of Agricultural Land Cover Using a Modified k-NN Technique (MNN) and Landsat Remote Sensing Imagery." *Remote Sensing* 1 (4): 875–895. doi:10.3390/rs1040875.
- Song, X., Z. Duan, and X. Jiang. 2012. "Comparison of Artificial Neural Networks and Support Vector Machine Classifiers for Land Cover Classification in Northern China Using a SPOT-5 HRG Image." *International Journal Remote Sensing* 33 (10): 3301–3320. doi:10.1080/01431161.2011.568531.
- Teodoro, A. C., and R. Araújo. 2014. "Exploration of the OBIA Methods Available in SPRING Noncommercial Software to UAV Data Processing." In *Proc. SPIE 9245, Earth Resources and Environmental Remote Sensing/GIS Applications V. 9245*. doi:10.1117/12.2066468.
- Walt, S. V. D., S. C. Colbert, and G. Varoquaux. 2011. "The NumPy Array: A Structure for Efficient Numerical Computation." *Computing in Science & Engineering* 13 (2): 22–30. doi:10.1109/MCSE.2011.37.

3.2 Artigo 2: Métodos de Pós-classificação baseado em objetos da cobertura e do uso da terra por meio de imagens com resolução espacial submétrica obtidas por Veículo Aéreo Não Tripulado (VANT)

RESUMO

Métodos de pós-classificação tem como objetivo principal reclassificar as classes de uma imagem classificada para aumentar sua precisão. As pós-classificações desenvolvidas atualmente consideram a classificação baseada em pixel, no entanto, imagens com resolução espacial submétrica apresentam uma alta variabilidade espectral que dificulta uma correta classificação baseada em pixel. Assim, entende-se que métodos de pós-classificação devam considerar a classificação baseada em objeto e seu contexto espacial. Este trabalho tem como objetivo desenvolver e avaliar dois métodos de pós-classificação: (i) Votação dos Objetos Vizinhos (VOV); (ii) Quantificação das Fronteiras dos Objetos (QFO); (iii) comparar a proposta de pós-classificação com o método Votação Baseada em Objetos (VBO). Os métodos foram desenvolvidos na linguagem de programação Python 2.7, com auxílio da *Geospatial Data Abstraction Library* (GDAL), da biblioteca SciKit-Image e do Numpy. A segmentação da ortoimagem foi realizada no programa Spring. Como método de classificação, foi utilizado o *Random Forest*. O método de pós-classificação VOV aumentou os valores de PC em 3,2%, alcançando uma acurácia de 95,7%. A pós-classificação QFO resultou em um aumento de 4,5%, obtendo uma acurácia de 97,0% no melhor caso. O método VBO não apresentou bons resultados na pós-classificação de imagens com resolução espacial submétrica.

Palavras-chave: pós-processamento, cobertura e uso da terra, Análise de Imagens Baseada em Objetos.

1 INTRODUÇÃO

Imagens obtidas por câmaras convencionais acopladas a Veículo Aéreo Não Tripulado (VANT), com resolução espacial submétrica, têm contribuído para estudos que demandam monitoramento (PEÑA et al., 2015) e dados de locais de difícil acesso. Além disso, mostram-se menos dispendiosas na coleta de imagens (HUSSON et al., 2016).

A determinação de classes de cobertura e do uso da terra por meio dessas imagens, comumente, compreende etapas de pré-processamento, extração das características, classificação e validação. O pré-processamento consiste em reduzir a variabilidade espectral das imagens, utilizando, para isso, a Análise de Imagens Baseada em Objetos (*Object-Based Image Analysis – OBIA*) (LALIBERTE, BROWNING & RANGO, 2012; LALIBERTE & RANGO, 2011).

A OBIA utiliza a segmentação para agrupar pixels homogêneos e formar os objetos geográficos, proporcionando a extração de características contextuais e geométricas (BLASCHKE et al., 2014). Essas características somam-se às espectrais e às texturais, que podem ser extraídas da imagem bruta. O conjunto de características resultante é de alta dimensionalidade, redundante e, alguns deles, não seguem qualquer distribuição conhecida. Devido a isso, são empregadas técnicas não paramétricas para a classificação da cobertura e uso da terra. Tais técnicas possibilitam a seleção de características relevantes, conseqüentemente, a redução da dimensionalidade e, posteriormente, a classificação da cobertura e uso da terra (LALIBERTE & RANGO, 2011).

Uma etapa pouco abordada nos trabalhos de classificação de imagens com resolução espacial submétrica é o pós-processamento da classificação, também denominada de pós-classificação. A etapa de pós-classificação tem como objetivo principal reclassificar as classes de uma imagem classificada para aumentar sua precisão (HUANG et al., 2014).

Guo & Moore (1991) apresentaram quatro métodos de pós-classificação para dados do Landsat, sensor *Thematic Mapper*. O método *Template Histogram Matching Classification* tem o intuito de avaliar padrões e texturas em uma imagem classificada, considerando a frequência das classes em uma janela móvel. O segundo método *Iterative Majority Filtering* se baseia em uma janela móvel sobre a imagem classificada, reclassificando o pixel central para a classe mais frequente da janela, o usuário ainda pode controlar o número de vezes (iteração) que a janela móvel percorre a classificação. A terceira pós-classificação, a *Small Class Merging*, reclassifica o pixel central de uma janela móvel, considerando o contexto das classes de uma classificação baseada em pixel e a distância espectral. O último método de pós-classificação, o *Class Boundary Detection*, utiliza-se de máscaras para detectar e delimitar os limites entre as classes de uma classificação

baseada em pixel, assim o pixel analisado será modificado considerando o limite entre seus vizinhos.

Solaiman et al. (1998) propõem um método de pós-classificação para dados de média resolução espacial. O algoritmo considera um mapa de bordas extraído da imagem e uma etapa de segmentação por crescimento de regiões, visto que a segmentação baseia-se no mapa de bordas e de uma classificação baseada em pixel suavizada.

Tarabalka et al. (2008) apresentam um método de classificação para dados hiperespectrais (103 bandas) e de alta resolução espacial (1,3 metros), que se fundamenta na classificação baseada em pixel e na segmentação por bacias para formar objetos homogêneos. A classificação baseada em pixel foi utilizada para definir as classes dos objetos, para isso, foi realizada uma contagem do número de pixels contidos nos objetos, assim, a classe mais votada (frequente) é atribuída ao objeto analisado. Os autores relatam que aumentaram as acurácias em mais de 4%, quando comparado com uma classificação baseada em pixel.

Apesar de Tarabalka et al. (2008) definirem seu método como uma classificação, Huang et al. (2014) o delimitam como uma pós-classificação, denominada de Votação Baseada em Objetos (VBO). Os autores definiram quatro grupos de pós-classificação: Filtragem, Campos aleatórios de Markov, VBO e reaprendizagem. *Iterative Majority Filtering* é um exemplo da pós-classificação por filtragem. Campo aleatório, de Markov, é um método probabilístico que integra contexto espacial em problemas de classificação baseada em pixel. Já a reaprendizagem tem o intuito de aprender iterativamente a imagem classificada, considerando a frequência e a disposição espacial das classes.

Xin et al. (2014) obtiveram classificações mais acuradas utilizando a pós-classificação de reaprendizagem para imagens de alta resolução espacial, sendo superior à classificação baseada em pixel. Geiss & Taubenbock (2015) avançaram com ideia de reaprendizagem e sugeriram uma técnica que utiliza classificação baseada em pixel e diferentes níveis de segmentação.

No entanto, as pós-classificações supracitadas consideram a classificação baseada em pixel. Imagens com resolução espacial submétrica apresentam uma alta variabilidade espectral, com isso, as características de uma classe são muito distintas, dificultando ou até mesmo impossibilitando a sua separação, e tais dificuldades são agravadas na classificação baseada em pixel (PEÑA et al., 2015; YU et al., 2006). Assim, entende-se que métodos de pós-classificação devam considerar a classificação baseada em objeto e seu contexto espacial.

Neste contexto, este trabalho tem como objetivo desenvolver e avaliar dois métodos de pós-classificação: (i) Votação dos Objetos Vizinhos (VOV), considera a classificação baseada em objeto e a segmentação para atribuir a classe do objeto da classificação; (ii) Quantificação das Fronteiras

dos Objetos (QFO), quantifica as fronteiras dos objetos de uma classificação baseada em objetos para determinar sua classe; e (iii) comparar as propostas de pós-classificação com o método Votação Baseada em Objetos (VBO).

2 METODOLOGIA

2.1 Desenvolvimento dos métodos de pós-classificação

Com intuito de elucidar os métodos de pós-classificação propostos neste trabalho, foi elaborada a Figura 1. A pós-classificação baseada na Votação dos Objetos Vizinhos (VOV) seleciona os objetos da segmentação com áreas menores que um limiar preestabelecido pelo usuário. Esse limiar é denominado a partir daqui como Tamanho Mínimo do Objeto (TMO), posteriormente, determina quais objetos são seus vizinhos e verifica, com auxílio da classificação, qual a classe de cada objeto. Assim, a classe mais votada será atribuída para o objeto selecionado.

A Figura 1c demonstra o resultado obtido com a pós-classificação VOV, nesse caso, foi selecionado o objeto 1 (Figura 1a), que possui oito objetos vizinhos. Analisando as classes dos objetos vizinhos por meio da classificação (Figura 1b), verifica-se que os objetos 8, 2, 3 e 4 foram classificados como C; os objetos 5, 6, 7, como B, e o objeto 1 como A. A classe que recebeu o maior número de votos foi a classe C, então, o objeto 1 foi classificado como classe C (Figura 1c).

A pós-classificação baseada na QFO seleciona os objetos da classificação com valores menores que o TMO, obtém os seus objetos vizinhos e quantifica a fronteira de cada objeto, assim, o objeto selecionado recebe a classe com maior valor de fronteira. A Figura 1d ilustra o resultado da pós-classificação obtida pelo método QFO, considerando os objetos da classificação da Figura 1b. A classificação compreende três classes, nesse caso, o objeto com a classe A foi selecionado, e as fronteiras entre os objetos vizinhos foram quantificadas, que são os objetos com as classes B e C. O maior valor de fronteira foi obtido pelo objeto com a classe B, então, o objeto analisado recebe a classe B (Figura 1d).

Para o desenvolvimento dos métodos propostos, foi utilizada a linguagem de programação Python 2.7 e o Ambiente de Desenvolvimento Científico para Python (*Scientific PYTHON Development Environment* - Spyder). As leituras e escritas das imagens georreferenciadas foram realizadas com a Biblioteca de Abstrações de dados Geo-Espaciais (*Geospatial Data Abstraction Library* - GDAL). As análises dos objetos da segmentação e da classificação foram efetuadas com as bibliotecas scikit-image e Numpy.

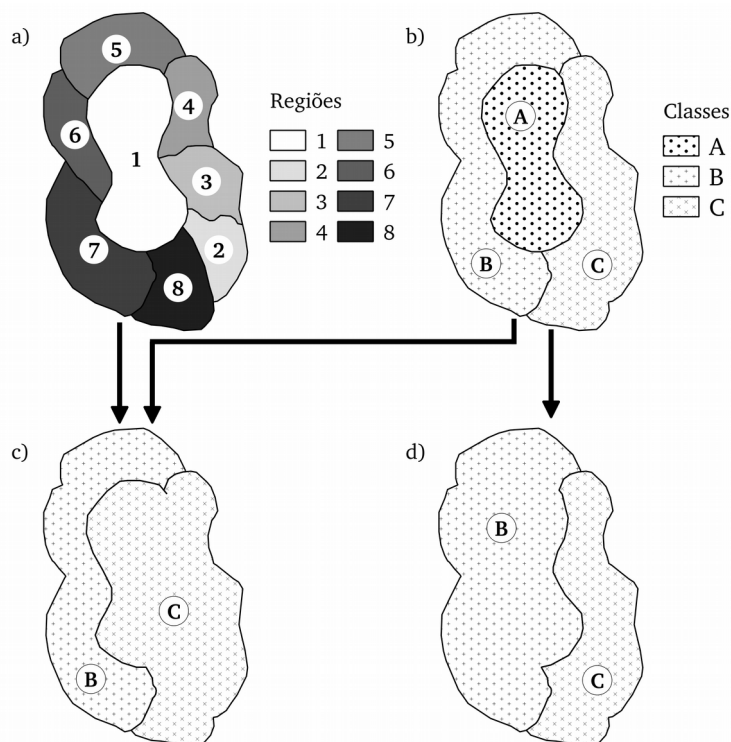


Figura 1 – Métodos de pós-classificação: a) segmentação; b) classificação baseada em objetos; c) pós-classificação obtida pela VOV; d) pós-classificação obtida pela QFO.

2.2 Avaliação dos métodos de pós-classificação

Os métodos de pós-classificação propostos dependem de uma segmentação e de uma classificação baseada em objetos. Para isso, foi adquirida uma ortoimagem com o VANT Echar 20B, utilizando uma câmera Sony de 36 megapixel, modelo ILCE-7R, resultando em uma ortoimagem com resolução espacial de 15 cm (Figura 2a). Essa câmera compreende bandas do azul (370-520 nm), do verde (470-570 nm) e do Infravermelho Próximo (IVP - 670 a 770 nm). O voo foi realizado sobre 73,15 hectares da Estação Experimental da Universidade Federal do Rio Grande Sul (UFRGS), com uma sobreposição entre faixas de 80% e entre fotos de 60%. A ortoimagem foi gerada no programa PhotoScan da empresa Agisoft, seguindo o fluxo de trabalho: entrada dos dados auxiliares (IMU, GNSS e calibração da câmera), alinhamento das imagens (descritores e calibração das cores e do brilho), otimização do alinhamento, determinação da nuvem de pontos densa, triangulação e obtenção da ortoimagem (Agisoft, 2016).

A segmentação da ortoimagem foi efetuada com o método crescimento de regiões disponível no programa Spring do Instituto Nacional de Pesquisas Espaciais (INPE). Os resultados obtidos por esse método são sensíveis aos valores dos limiares de similaridade e de tamanho mínimo dos objetos (ESPINDOLA et al., 2006). Devido a isso, foram testados os valores de similaridade 1, 2, 5,

10, 15, 20, 30, 40 e 50. Para o número mínimo de pixels, foram avaliados os valores 20, 50 e 100 (TEODORO & ARAÚJO, 2014).

A classificação baseada em objetos foi realizada com o método *Random Forest*, avaliando os valores de 5 até 30, variando 5 para os parâmetros: número de árvores (estimadores) e a profundidade da árvore. As amostras de treinamento foram geradas por meio de uma grade regular, com equidistâncias de 25 metros, totalizando 825 pontos. Para validar as classificações, foram gerados 400 pontos aleatórios independentes dos dados de treinamento. A atribuição das classes desses pontos ocorreu por meio da interpretação da ortoimagem. Para isso, foram consideradas as seguintes classes de cobertura e uso da terra: Pastagem, Resteva, Solo Úmido, Água, Água/Cinza, Banhado e Campo. O conjunto de características geométricas, contextuais, espectrais e texturais utilizado na classificação baseada em objetos está ilustrado na Tabela 1.

Tipos	Características	Referências
Geométricos	Compacidade; suavidade; retangularidade; isometria; anisometria; <i>bulkiness</i> ; excentricidade; <i>roudness</i> ; fator de forma circular e área.	(FERREIRA, COSTA & FEITOSA, 2013)
Contextuais	Cálculo da diferença média dos valores das bandas do objeto entre seus vizinhos	(LALIBERTE et al., 2011)
Espectrais	- Cálculo dos valores médios e do desvio padrão das bandas - Razões entre as bandas	
Texturais	Valores médios das texturas extraídas a partir da matriz de <i>Grey Level Cooccurrence Matriz</i> , para os ângulos 0°, 45°, 90° e 135°. <i>Angular Second Moment, Correlation, Entropy, Contrast, Sum Average, Difference Entropy, Sum Entropy, Variance, Inverse Difference Moment, Difference Variance, Sum Variance, Information Measures of Correlation e Maximal Correlation Coefficient.</i>	(HARALICK, SHANMUGAM & DINSTEN, 1973; LALIBERTE & RANGO, 2009)

Tabela 1 – Conjunto de características geométricas, contextuais, espectrais e texturais.

O melhor caso da classificação baseada em objetos foi submetido aos dois métodos de pós-classificação. Como os métodos dependem do TMO, foram avaliados valores de 0 até 10000, no passo de 200 (unidade pixels). As pós-classificações foram avaliadas com amostras de referência, Figura 2c, que são independentes das amostras na classificação baseada em objetos.

Para comparar os resultados dos métodos de pós-classificação, foi desenvolvida a pós-classificação Votação Baseada em Objetos (VBO), conforme Tarabalka et al. (2008). O método VBO depende de uma classificação baseada em pixel e dos objetos da segmentação. A classificação baseada em pixel foi desenvolvida por meio do método *Random Forest* e foram avaliados os mesmos valores dos parâmetros na classificação baseada em objetos.

As amostras de treinamento e de validação no formato de pontos foram utilizadas para selecionar os objetos de uma segmentação. Os objetos selecionados foram utilizados para amostrar os valores das características e formar o conjunto amostral de treinamento e de validação para a classificação baseada em pixel. As características utilizadas na classificação baseada em pixel foram: as bandas da imagem, as razões entre as bandas e as texturas (Tabela 1). A classificação baseada em pixel mais acurada e a segmentação que resultou no melhor caso da classificação baseada em objetos foram utilizadas no método VBO. O método VBO também foi avaliado em relação às amostras de referência apresentadas na Figura 2c.

As acurácias da classificação e pós-classificação foram avaliadas pelo índice de Proporção Correta (PC), pelo Desacordo de Alocação (DA) e pelo Desacordo de Quantidade (DQ), propostos por Pontius & Millones (2011). Também foram avaliadas se as diferenças entre as acurácias dos melhores casos das pós-classificações em relação à classificação baseada em objetos são estatisticamente significativas. Para isso, foi calculado o teste de proporção, e o resultado foi comparado com um nível de significância de 5%. A aceitação da hipótese nula (H_0) considera que as acurácias não são diferentes, já a hipótese alternativa (H_1), que as acurácias são diferentes. As classificações com o método *Random Forest* foram realizadas com a biblioteca SciKit-Learn, e as acurácias foram computadas com auxílio do Numpy.

3 RESULTADOS

3.1 Classificação baseada em objetos e amostras de referência

A ortoimagem da área estudo com as respectivas classes de cobertura e de uso da terra está apresentada na Figura 2a. O melhor caso da classificação baseada em objetos está ilustrado na Figura 2b, que foi obtido com similaridade igual a 15 e número mínimo de pixel igual a 100 para a segmentação, utilizando número de árvores igual a 20 e profundidade igual a 30 para o método *Random Forest*. Avaliando a classificação baseada em objetos com as amostras de referência, Figura 2c, obteve-se um PC igual a 91,3%, DQ igual a 6,9% e DA igual a 1,8%. Essa classificação baseada em objetos foi utilizada nas avaliações dos métodos de pós-classificação VOV e QFO.

Na avaliação da classificação baseada em objetos (Figura 2a), verifica-se o efeito “sal e pimenta” para algumas classes, como o Solo úmido, contendo vários objetos de diferentes classes. A classe Banhado é uma das mais complexas, porque apresenta variação do vigor vegetativo e da umidade do solo. Devido a isso, a classificação resultante apresenta objetos classificados como: Campo, Solo úmido, Resteva e Pastagem em áreas de Banhado. Erros de classificação também foram observados para a classe Campo ao redor da Água/cinza, nesse local, o Campo apresenta uma textura diferenciada e pode ser o motivo da confusão com a classe Pastagem e Banhado. A maioria desses erros de classificação ocorre devido à semelhança espectral e textural entre as classes. Assim, pode-se inferir que métodos de pós-classificação que consideram características texturais e/ou espectrais não melhorariam as acurácias dos mapeamentos.

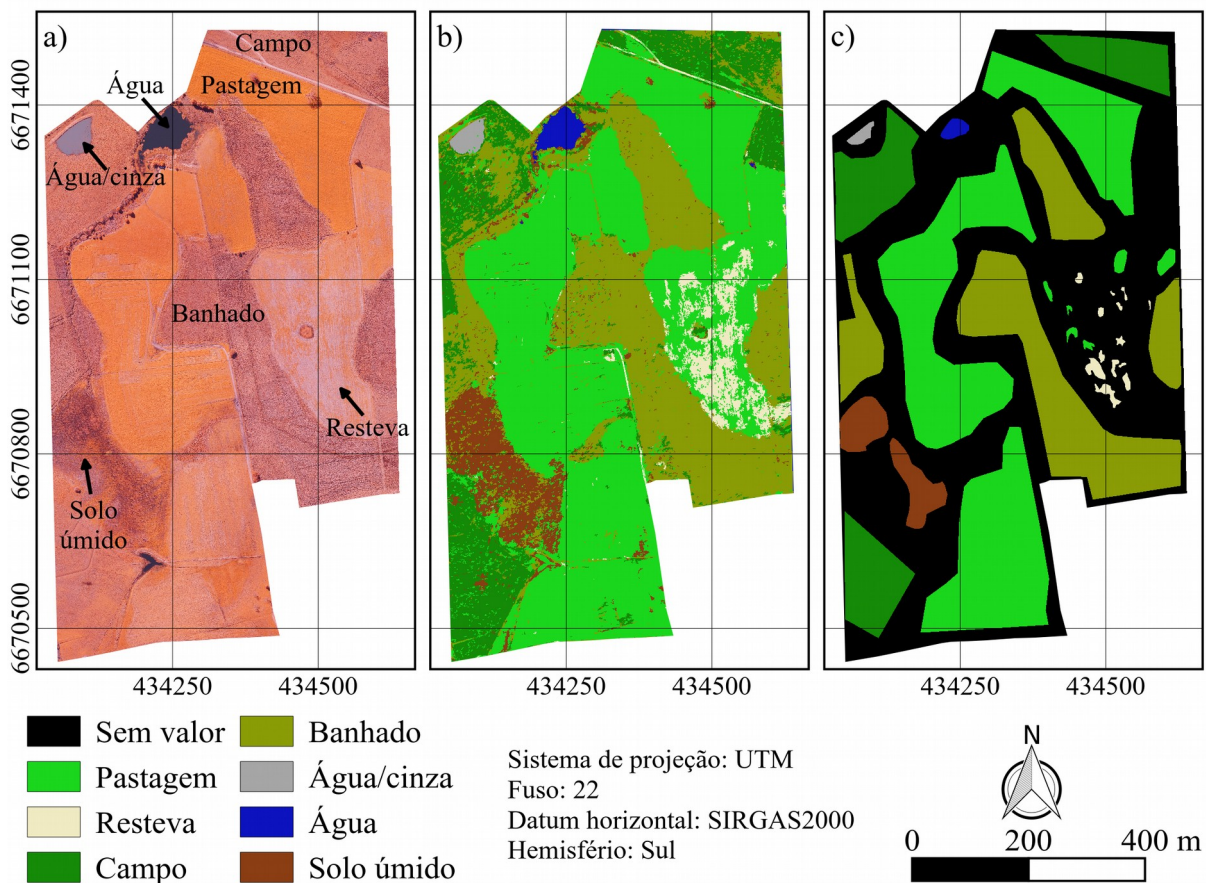


Figura 2 – a) ortoimagem na composição Azul/ banda azul, Verde/ banda verde e Vermelho/ banda infravermelho próximo; b) Classificação baseada em objetos; e c) amostras de referencia da cobertura e do uso da terra.

3.2 Pós-classificação baseada na Votação dos Objetos Vizinhos (VOV) e na Quantificação das Fronteiras dos Objetos (QFO)

VOV analisa os objetos da segmentação, quantifica os objetos vizinhos, considerando a classificação, e atribui a classe mais votada para o objeto analisado. A Figura 3a apresenta as acurácias de ambos os métodos de pós-classificação, e a Figura 3b apresenta o total de objetos avaliados para o método VOV em relação aos respectivos valores de TMO. Na primeira avaliação do método, utilizando TMO igual a 0, foi obtida uma acurácia igual a 92,5%. Na segunda pós-classificação, utilizando TMO igual a 200, a acurácia obtida foi de aproximadamente 93,7%, resultando em um aumento de 1,2%. As acurácias da pós-classificação VOV continuam crescendo até TMO igual a 7000, alcançando valores de PC iguais a 95,7%.

A Figura 3b mostra o total de objetos analisados para cada TMO. Para TMO igual a 200, foram avaliados 21185 objetos. Esse total passa dos 50000 objetos, quando TMO recebe o valor 1200. Após esse valor de TMO, quase todos os objetos da segmentação são avaliados, isso ocorre porque os 51630 objetos da segmentação possuem, quase que na sua totalidade, objetos menores que 1200 pixels.

No geral, observa-se que, com o aumento do total de objetos analisados, há um acréscimo da acurácia, aumentando cerca de 3,2% a partir do TMO igual 7000. Nesse sentido, é possível determinar um valor de TMO ótimo, uma vez que as acurácias estabilizaram a partir do TMO igual a 7000. Assim, o método de pós-classificação VOV, utilizando o contexto espacial dos objetos da segmentação, possibilitou um aumento da acurácia e pode ser uma alternativa de pós-classificação para imagens com resolução espacial submétrica obtidas por VANT.

QFO analisa os objetos formados pela classificação, quantifica a fronteira dos objetos vizinhos e atribui a classe com a maior fronteira para o objeto analisado. A Figura 3c apresenta o total de objetos avaliados para o método QFO em relação aos valores de TMO. Na primeira avaliação, utilizando TMO igual a 0, foi obtido um valor de PC igual a 92,5%. Quando a pós-classificação QFO recebe TMO igual a 200, a acurácia aumenta para 93,5% (Figura 3a), avaliando cerca de 3411 objetos (Figura 3c). As acurácias apresentaram um comportamento crescente até TMO igual a 9400 (Figura 3a), alcançando um valor de PC igual a 97,0% e, a partir desse valor de TMO, as acurácias estabilizaram. Esses resultados mostram que há um valor de TMO ótimo, que considera o maior número de objetos erroneamente classificados, resultando no aumento das acurácias.

A Figura 3c evidencia que, quando a pós-classificação recebe TMO igual a 1600, o total de objetos avaliados ultrapassa os 7000, e que, a partir desse valor de TMO, há um sutil crescimento

do total de objetos avaliados, alcançando os 7604 objetos para TMO igual a 10000, dos 7724 objetos da classificação. Mesmo com um t enu aumento do total de objetos avaliados, o crescimento das acur cias   expressivo. Isso ocorre porque, com o aumento do valor do TMO, o total e o tamanho dos objetos avaliados tamb m aumentam, proporcionando que um maior n mero de objetos sejam p s-classificados.




Figura 3 – Resultados das p s-classifica es QFO e VOV para distintos valores do Tamanho M nimo do Objeto (TMO): a) acur cias; b) total de objetos para VOV; b) total de objetos para QFO.

A pós-classificação QFO resultou em um aumento de 4,5% da acurácia final para TMO maior que 9400, avaliando cerca de 98,3% dos objetos da classificação baseada em objetos. Também foi verificado que, com o aumento dos objetos avaliados, ou seja, maiores valores TMO, as acurácias também aumentaram, assim, entende-se que os objetos avaliados foram reclassificados corretamente pelo método de pós-classificação QFO.

3.3 Comparação entre os métodos de pós-classificação

O melhor caso da classificação baseada em pixel foi obtido com número de árvores igual a 10 e profundidade igual a 15, obtendo um PC igual a 93,1%. A pós-classificação VBO (Figura 4a) foi aplicada na classificação baseada em pixel com a segmentação, similaridade igual a 15 e número mínimo de pixels igual a 100, resultando em um PC igual a 63,2%. Na pós-classificação VBO, Figura 4a, verifica-se que as classes Solo Úmido e Banhado foram quase totalmente subestimadas, e as classes Campo e Resteva foram superestimada. Isso ocorreu porque a classificação baseada em pixel também superestimou as classes Campo e Resteva. Desse modo, no momento da votação dos pixels para os objetos, as classes Campo e Resteva foram as mais votadas. Tarabalka et al. (2008) obtiveram resultados mais satisfatórios utilizando uma imagem com resolução espacial de 1,3 m. Os autores utilizaram uma segmentação baseada em bacias e uma classificação baseada em pixel com o método SVM na pós-classificação VBO, aumentando o desempenho do mapeamento da cobertura e do uso da terra de aproximadamente de 4,56%, quando comparado com a classificação baseada em pixel.

A Figura 4b mostra a pós-classificação VOV com TMO igual a 7000, que resultou em um valor de PC igual a 95,7%. Comparando o método de pós-classificação VOV com a classificação baseada em objetos (Figura 2b), identifica-se que alguns objetos pertencentes às classes Solo Úmido, Pastagem e Banhado, erroneamente classificados, foram corretamente pós-classificados pelo método. Essa eficiência da pós-classificação está relacionada com o número de objetos isolados da classificação, uma vez que a ocorrência de objetos isolados facilita o acerto da pós-classificação.

Como a pós-classificação VOV avalia os objetos da segmentação nos locais em que grupos de objetos são classificados erroneamente, o método VOV não pós-classifica os objetos corretamente. Esse comportamento pode ser observado para a classe Campo, em que grupos de objetos foram classificados como Pastagem e inviabilizaram uma correta pós-classificação. O mesmo comportamento ocorreu para os locais de Campo, entorno da classe Água/cinza, equivocadamente classificados como Banhado.

Ao avaliar a pós-classificação QFO, Figura 4c, obtida com TMO igual a 9400 que resultou em um PC igual a 97,0% , observa-se que os objetos erroneamente classificados na classe Campo foram corretamente pós-classificados pelo método. Isso ocorreu porque o método QFO avalia os objetos da classificação baseada em objetos e, diferente da pós-classificação VOV, não há objetos vizinhos com a mesma classe do avaliado, assim, os objetos foram pós-classificados corretamente.

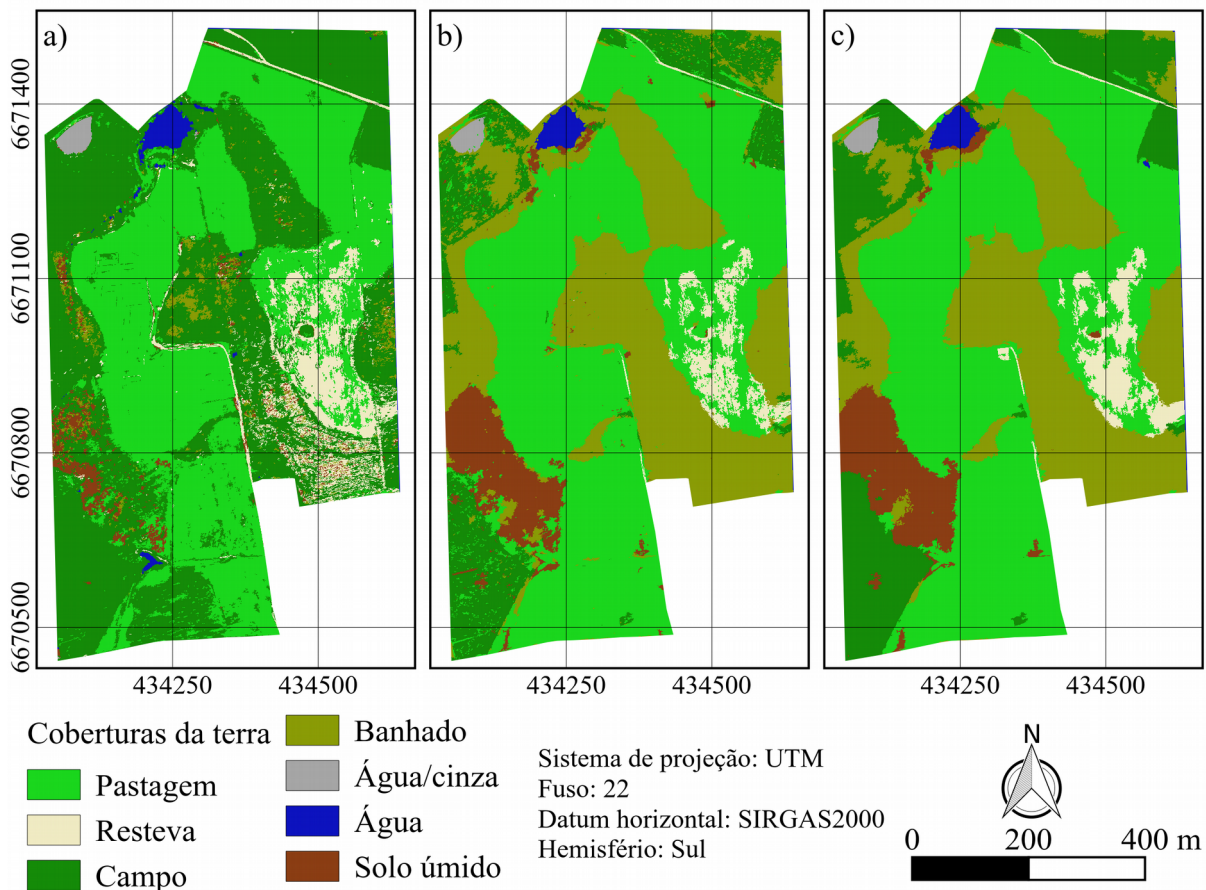


Figura 4 – Resultados das pós-classificações; a) Votação Baseada em Objetos (VBO); b) Votação dos Objetos Vizinhos (VOV); e b) Quantificação das Fronteiras do Objetos (QFO).

Comportamento oposto pode ser observado para os objetos com área maior que TMO, como o obtido para a classe Banhado, entorno da Água/cinza, visto que a área de Banhado permaneceu erroneamente classificada (Figura 4c). Isso ocorreu porque a área classificada como Banhado, nesse local, é maior que os valores de TMO avaliados.

No entanto, utilizar altos valores de TMO pode degradar as acurácias dos mapeamentos, porque objetos corretamente classificados, como os observados para a classe Água, Figura 4c, poderiam ser pós-classificados em outra classe. Isso justifica a importância de analisar-se diferentes valores de TMO.

A comparação entre os métodos de pós-classificação indica que o método VBO, nesta pesquisa, não foi adequado para a pós-classificação da cobertura e do uso da terra a partir de imagens com resolução espacial submétrica obtidas por VANT.

Já os métodos propostos melhoraram a correspondência da classificação baseada em objeto com a ortoimagem, diminuindo o efeito de “sal e pimenta”. Calculando o teste de proporção com as acurácias obtidas pelos melhores casos dos métodos VOV (95,7%) e QFO (97,0%) em relação à acurácia da classificação baseada em objetos, foi constatado que as acurácias são estatisticamente diferentes, quando avaliadas em um nível de significância de 5%, ou seja, rejeitamos a hipótese nula. Com isso, entende-se que o uso de ambos os métodos, VOV e QFO, aumentaram a acurácia do mapeamento e foram adequados para a pós-classificação da cobertura e uso da terra por meio de imagens com resolução espacial submétrica obtidas por VANT.

Pande-Chhetri et al. (2017), com o objetivo de classificar espécies vegetais em áreas úmidas utilizando classificação multirresolução baseada em objetos e imagens obtidas por VANT, propuseram um método de pós-classificação que utiliza informações temáticas e contextuais das espécies. Inicialmente, o método considerou a proximidade com a classe Água para diferenciar vegetais submersos e emersos, posteriormente, as variações espectrais e texturais para separar os vegetais emersos em demais classes. Os autores refinaram a classificação baseada em objetos empregando esse método de pós-classificação, melhorando o desempenho do mapeamento das espécies vegetais em áreas úmidas.

4 CONCLUSÕES

O método de pós-classificação VOV, que considera a segmentação e a classificação baseada em objeto, aumentou as acurácias das pós-classificação de 92,5% para 95,7%, quando TMO recebeu valores maiores que 7000. O método VOV teve dificuldades em pós-classificar grupos de objetos classificados erroneamente. No método de pós-classificação QFO, o aumento das acurácias das pós-classificação foi superior, o método possibilitou um aumento de 92,5% para 97,0%, quando TMO recebeu valores superiores a 9400.

Os métodos de pós-classificação propostos, VOV e QFO, também melhoraram a correspondência da classificação baseada em objeto com a ortoimagem, diminuindo o efeito de “sal e pimenta”. Assim, recomenda-se o uso de ambos os métodos para a pós-classificação da cobertura e uso da terra de imagens com resolução espacial submétrica obtidas por VANT.

A partir da comparação dos métodos de pós-classificação, conclui-se que o método VBO não foi adequado para a pós-classificação da cobertura e do uso da terra por meio de imagens com resolução espacial submétrica obtidas por VANT.

Com base nos estudos desenvolvidos, verifica-se a importância de trabalhos futuros abordarem valores das probabilidades resultantes dos métodos de classificação baseada em objetos, uma vez que objetos classificados com baixa probabilidade podem ter sido classificados erroneamente.

REFERÊNCIAS

- AGISOFT. 2016 “Support Tutorials.” Acessado em janeiro de 2017. <http://www.agisoft.com/support/tutorials/intermediate-level>
- BLASCHKE, T. et al. Geographic Object-Based Image Analysis – Towards a new paradigm. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 180–191, 1 jan. 2014.
- COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 20, n. 1, p. 37–46. 1960.
- ESPINDOLA, G. M. et al. Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation. **International Journal of Remote Sensing**, v. 27, n. 14, p. 3035–3040, 20 jul. 2006.
- FERREIRA, R. DA S.; COSTA, G. A. O. P.; FEITOSA, R. Q. Avaliação de critérios de heterogeneidade baseados em atributos morfológicos para segmentação de imagens por crescimento de regiões. **Boletim de Ciências Geodésicas**, v. 19, n. 3, p. 452–471, set. 2013.
- GEISS, C.; TAUBENBOCK, H. Object-Based Postclassification Relearning. **IEEE Geoscience and Remote Sensing Letters**, v. 12, n. 11, p. 2336–2340, nov. 2015.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural Features for Image Classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. SMC-3, n. 6, p. 610–621, nov. 1973.
- HUSSON, E. et al. Comparison of Manual Mapping and Automated Object-Based Image Analysis of Non-Submerged Aquatic Vegetation from Very-High-Resolution UAS Images. **Remote Sensing**, v. 8, n. 9, p. 724, 1 set. 2016.
- LALIBERTE, A. S. et al. Multispectral Remote Sensing from Unmanned Aircraft: Image Processing Workflows and Applications for Rangeland Environments. **Remote Sensing**, v. 3, n. 11, p. 2529–2551, 22 nov. 2011.
- LALIBERTE, A. S.; BROWNING, D. M.; 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, 1 abr. 2012.
- LALIBERTE, A. S.; RANGO, A. Texture and Scale in Object-Based Analysis of Subdecimeter Resolution Unmanned Aerial Vehicle (UAV) Imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 761–770, mar. 2009.
- LALIBERTE, A. S.; 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, 15 jan. 2011.
- LIU JIAN GUO; MOORE, J. M. **Post-classification Processing For Thematic Mapping Based On Remotely Sensed Image Data**. [Proceedings] IGARSS’91 Remote Sensing: Global Monitoring

for Earth Management. **Anais...IEEE**, [s.d.]Disponível em: <<http://ieeexplore.ieee.org/document/575478/>>. Acesso em: 26 nov. 2018

PANDE-CHHETRI, R. et al. Object-based classification of wetland vegetation using very high-resolution unmanned air system imagery. **European Journal of Remote Sensing**, v. 50, n. 1, p. 564–576, 8 jan. 2017.

PEÑA, J. et al. Quantifying Efficacy and Limits of Unmanned Aerial Vehicle (UAV) Technology for Weed Seedling Detection as Affected by Sensor Resolution. **Sensors**, v. 15, n. 3, p. 5609–5626, 6 mar. 2015.

PONTIUS, R.G. JR. Quantification error versus location error in comparison of categorical maps. **Photogrammetric Engineering and Remote Sensing**, v. 66, p. 1011–1016. 2000.

PONTIUS, R. G.; MILLONES, M. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, v. 32, n. 15, p. 4407–4429, 10 ago. 2011.

SOLAIMAN, B. et al. An information fusion method for multispectral image classification postprocessing. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 2, p. 395–406, mar. 1998.

TARABALKA, Y. et al. **Segmentation and Classification of Hyperspectral Data using Watershed**. IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium. **Anais...IEEE**, 2008Disponível em: <<http://ieeexplore.ieee.org/document/4779432/>>. Acesso em: 5 nov. 2018

TEODORO, A. C.; ARAÚJO, R. **Exploration of the OBIA methods available in SPRING noncommercial software to UAV data processing**. (U. Michel, K. Schulz, Eds.)International Society for Optics and Photonics, 10 out. 2014Disponível em: <<http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.2066468>>. Acesso em: 5 nov. 2018

XIN H. et al. New Postprocessing Methods for Remote Sensing Image Classification: A Systematic Study. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 11, p. 7140–7159, nov. 2014.

YU, Q. et al. Objectbased detailed vegetation classification with airborne high spatial resolution remote sensing imagery. **Photogrammetric Engineering and Remote. SENSING**, 2006.

3.3 Artigo 3: GeoPatterns: Reconhecimento de Padrões e Análise de Imagens Baseada em Objetos (OBIA)

RESUMO

Técnicas não paramétricas de reconhecimento de padrões e Análise de Imagens Baseada em Objetos (*Object-Based Image Analysis - OBIA*) estão sendo utilizadas com sucesso na classificação da cobertura e do uso da terra com imagens de resolução espacial submétrica. No entanto, programas automatizados e acessíveis ainda são um obstáculo aos geocientistas. Nesse contexto, este trabalho tem como objetivos: (i) automatizar algoritmos que integram métodos não paramétricos de reconhecimento de padrões e OBIA; (ii) desenvolver uma interface amigável para essa integração, originando o programa GeoPatterns e (iii) avaliar os resultados oriundos do programa GeoPatterns em um estudo de caso com imagens obtidas por VANT. O programa GeoPatterns foi desenvolvido com a linguagem de programação Python 3 e distribuído como *plugin* para o Sistema de Informação Geográfica QGIS 3. O programa GeoPatterns possibilitou uma integração de técnicas não paramétricas de reconhecimento de padrões com OBIA, bem como uma automatização dos processos de segmentação, amostragem e classificação dos objetos. A interface gráfica tornou mais amigável a aplicação dessa metodologia em imagens com resolução espacial submétrica. Como os programas e as bibliotecas de programação necessárias para a utilização do GeoPatterns são gratuitas, os geocientistas podem usufruir das ferramentas sem qualquer custo. Aplicando os classificadores *Random Forest* e *k - Nearest Neighbor (k-NN)*, com o programa GeoPatterns, a classificação da cobertura e do uso da terra de imagens com resolução espacial submétrica alcançou acurácias superiores aos 90.0%.

Palavras-chave: GeoPatterns, imagens com resolução espacial submétrica, classificação baseada em objetos.

1 INTRODUÇÃO

O crescente aumento da disponibilidade de imagens de sensoriamento remoto com resolução espacial submétrica, obtidas tanto por satélites quanto por veículos aéreos tripulados e Veículos Aéreos Não Tripulados (VANT), criou um desafio para a classificação da cobertura e do uso da terra (MA et al., 2017). Técnicas convencionais, como a classificação baseada em pixel, resultaram em mapeamentos com o efeito de “sal e pimenta” (BLASCHKE et al., 2014) e demandaram um maior tempo na etapa de classificação de imagens com resolução espacial submétrica.

Análise de Imagens Baseada em Objetos (*Object-Based Image Analysis* - OBIA) tem substituído a classificação baseada em pixels. Na OBIA, as unidades de processamento são objetos geográficos (regiões) gerados pela segmentação da imagem e por métodos de clusterização. A classificação baseada em objetos ameniza as dificuldades da classificação baseada em pixel e ainda possibilita mapeamentos mais acurados da cobertura e do uso da terra com imagens de resolução espacial submétrica (BLASCHKE et al., 2014; PANDE-CHHETRI et al., 2017).

OBIA também possibilita uma análise das características contextuais e geométricas dos objetos geográficos, no geral, tais características não apresentam uma distribuição conhecida. Esse comportamento está sendo contornado com a utilização de técnicas não paramétricas de reconhecimento de padrões, pois essas técnicas desconsideram a distribuição dos dados. Técnicas não paramétricas de reconhecimento de padrões também propiciam a seleção de características mais relevantes, resultando em uma redução na dimensionalidade do conjunto de dados (LALIBERTE et al., 2011; PANDE-CHHETRI et al., 2017).

As metodologias de classificação que integram métodos não paramétricos de reconhecimento de padrões e OBIA consistem, principalmente, das seguintes etapas: segmentação, amostragem das características e classificação dos objetos geográficos. Laliberte & Rango (2011) avaliaram o fluxo de trabalho que contempla as etapas metodológicas supracitadas, utilizando o programa comercial eCognition no mapeamento de pastagens em escala submétrica. Hellesen & Matikainen (2013) também utilizaram o programa eCognition para classificação de arbustos e de árvores por meio dos dados de *Light Detection And Ranging* (LIDAR) e de imagens obtidas por VANT. Qian et al. (2014) avaliaram técnicas não paramétricas de reconhecimento de padrões e OBIA e utilizaram o programa comercial eCognition na segmentação da imagem e na amostragem das características. Para a classificação dos objetos geográficos, foi utilizada a biblioteca de programação de computação visual OpenCV. Teodoro & Araújo (2014) consideraram os programas gratuitos Spring e OTB/Monteverdi na classificação da cobertura da terra de uma área urbana por

meio de imagens de VANT. Contudo, os autores comentaram em sua metodologia que foram realizadas separadamente as avaliações dos parâmetros da segmentação e da classificação.

O desenvolvimento de programas automatizados, gratuitos e que integrem técnicas não paramétricas de reconhecimento de padrões e OBIA podem tornar essa metodologia menos complexa e mais acessível aos geocientistas. A partir dessas considerações, este trabalho tem como objetivos: (i) automatizar algoritmos que integram métodos não paramétricos de reconhecimento de padrões e OBIA; (ii) desenvolver uma interface amigável para essa integração, originando o programa GeoPatterns e (iii) avaliar os resultados oriundos do programa GeoPatterns em um estudo de caso com imagens obtidas por VANT.

2 METODOLOGIA

Com intuito de facilitar a compreensão das etapas envolvidas nos processos de automatização e da construção das interfaces gráficas do programa GePatterns, a metodologia foi dividida conforme as subseções apresentadas na Figura 1. A avaliação do GeoPatterns está apresentada na subseção 2.4 Estudo de caso.

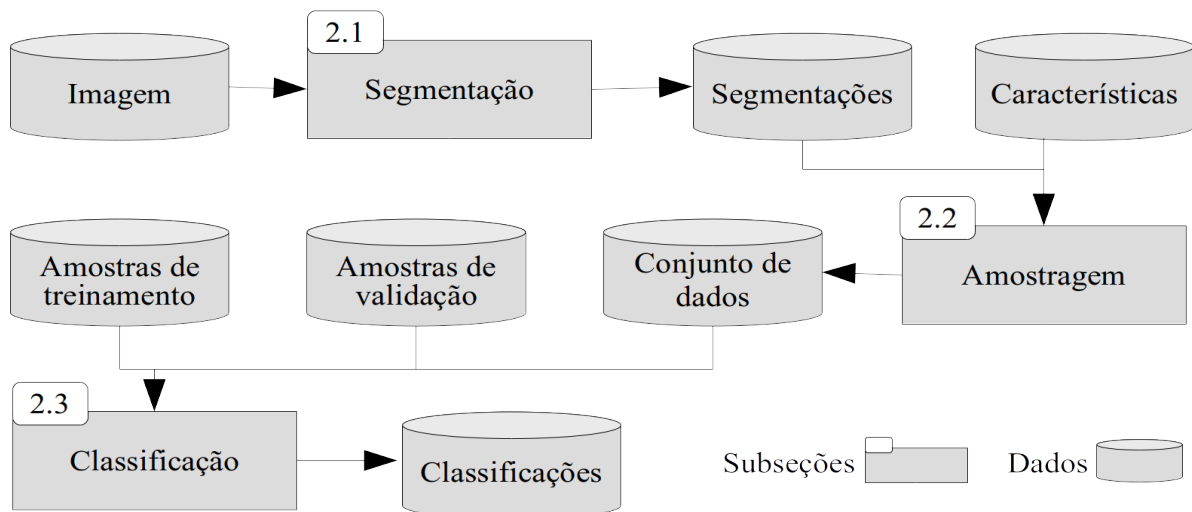


Figura 1. Fluxograma metodológico.

GeoPatterns foi desenvolvido com a linguagem de programação Python 3 e com bibliotecas de programação gratuitas. As interfaces gráficas das ferramentas foram desenvolvidas por meio do programa QtDesigner 5, posteriormente, convertidas para linguagem Python 3. De posse das interfaces gráficas, GeoPatterns foi integrado como *plugin* ao programa gratuito de Sistema de

Informação Geográfica QGIS 3, utilizando as bibliotecas de programação PyQt5 e PyQGIS e distribuído como programa gratuito.

2.1 Segmentação

Como método de segmentação, foi utilizada a ferramenta *i.segment* do programa *Geographic Resources Analysis Support System* (GRASS-GIS), GRASS-GIS pode ser integrado com QGIS3 no momento da instalação. Essa ferramenta utiliza o método de segmentação crescimento de regiões para gerar os objetos geográficos. O processo de segmentação por crescimento de regiões inicia a partir de um conjunto de pixels sementes, em que são analisadas as similaridades desses pixels com seus vizinhos. Pixels com valores similares são agrupados e, assim, são formados os objetos (ESPINDOLA et al., 2006), conforme Equação (1).

$$R = \left\{ \begin{array}{l} \text{Verdadeiro, Se } |f(x,y) - f(r,s)| \leq LS \\ \text{Falso, caso contrário} \end{array} \right\} \quad (1)$$

Em que: R é a região (objeto geográfico); $f(x,y)$ é o pixel semente; $f(r,s)$ são os pixels vizinhos; e LS é o limiar de similaridade definido pelo usuário.

Para o *i.segment*, os pixels sementes podem ser gerados de forma aleatória ou inseridos pelo usuário. A ferramenta também possibilita que usuário insira um raster que identifique as bordas dos objetos. O crescimento das regiões (objetos), ou seja, o agrupamento dos pixels similares é controlado pelo limiar de similaridade, que varia de 0 a 1, quanto maior esse valor, maior a liberdade de crescimento das regiões (objetos geográficos). Outro parâmetro importante é o Tamanho Mínimo dos Objetos (TMO), quanto menor esse valor, menores serão os objetos geográficos gerados pela segmentação. A ferramenta *Segmentation* do GeoPatterns foi desenvolvida na linguagem de programação Python 3, com auxílio do framework *Processing* do QGIS3 para importar a ferramenta *i.segment*. As bibliotecas *geopandas* e *PyQGIS* foram usadas para realizar as leituras e saídas dos arquivos.

2.2 Amostragem

Para amostrar as características, foi utilizada a ferramenta *Zonal Statistics* do programa QGIS3, em que é possível realizar o cálculo de estatísticas básicas das características para cada

objeto geográfico gerado pela segmentação. Como são geradas várias segmentações com diferentes parâmetros e são utilizadas várias características para construir o conjunto de dados, a ferramenta *Sampling*, desenvolvida neste trabalho, realiza a leitura de cada segmentação e de cada característica, calcula as estatísticas básicas e cria um campo na tabela para cada estatística selecionada pelo usuário.

O desenvolvimento da ferramenta *Sampling* foi realizado com a linguagem de programação Python 3. Para importar a ferramenta Zonal Statistics, foi utilizado o framework *Processing* do QGIS3. Para as leituras e saídas dos arquivos, foram utilizadas as bibliotecas *geopandas* e *PyQGIS*.

2.3 Classificação baseada em objetos

Os métodos de classificação utilizados foram os classificadores não paramétricos *Random Forest* (RF) e *k - Nearest Neighbor* (k-NN). *Random Forest* (RF) é categorizado como classificador do tipo *ensemble*. Esse método divide as amostras de treinamento em subconjuntos e gera uma árvore de decisão para cada subconjunto. Após o modelo treinado, a classificação de um novo exemplo é obtida pela votação de cada árvore, assim, a amostra é classificada na classe mais votada (BREIMAN, 2001). Árvore de decisão é um modelo binário, construído dividindo o conjunto de dados de entrada em nós cada vez mais homogêneos, escolhendo o valor da característica que minimiza a impureza do nó. O número de árvores, sua profundidade máxima e o critério de divisão dos nós são parâmetros ajustáveis. Como critério para divisão dos nós, é possível selecionar Gini (Equação 2) e Entropia (Equação 3).

$$Gini = 1 - \sum_{i=1}^c (p_i)^2 \quad (2)$$

$$Entropia = 1 - \sum_{i=1}^c p_i \log_2(p_i) \quad (3)$$

Em que: c é o número total de classes e p_i é a probabilidade classe i .

k-NN baseia-se na determinação de amostras de treinamento mais próximas aos dados sem classes, classificando-os em relação à classe mais frequente dos vizinhos selecionados (OOI, NG & LIM, 2013). A matriz de distância permite entender a proximidade de cada amostra com os dados não classificados. O número total de linhas da matriz é igual ao número de dados não classificados, e o número de colunas é igual ao número de amostras de treinamento. Neste trabalho, utilizou-se a variante da métrica Minkowski, dada pela Equação (4).

$$d(A,B) = \left(\sum_{a=1}^t |A_a - B_a|^{\text{exp}} \right)^{1/\text{exp}} \quad (4)$$

Em que: d é a distância; A é o vetor de características das amostras de treinamento; B é o vetor de características do dado não classificado; t é o total de características; e exp é o expoente da equação.

Para cada classificador, foi desenvolvida uma interface gráfica que possibilita ler as segmentações, avaliar os parâmetros e informar as saídas dos arquivos. As ferramentas de classificação *Random Forest* (RF) e k-NN foram desenvolvidas utilizando a linguagem de programação Python 3 e a biblioteca de programação Scikit-Learn 0.19. Para as leituras e saídas dos arquivos, foram utilizadas as bibliotecas geopandas e PyQGIS.

A validação das classificações foi realizada por meio do cálculo da Proporção Correta (PC), do Desacordo de Alocação (DA) e do Desacordo de Quantidade (DQ), conforme estudo de Pontius & Millones (2011). Para o melhor caso de cada método foram avaliadas a matriz de confusão, a Precisão do Produtor (PP) e a Precisão do Usuário (PU) (GU, CONGALTON & PAN, 2015). Também foram avaliadas se as diferenças entre as acurácias são estatisticamente significantes, utilizando como base o teste de proporção em um nível de significância de 5%. A aceitação da hipótese nula (H_0) considera que as acurácias não são diferentes, já sua rejeição, a hipótese alternativa (H_1), que as acurácias são diferentes. Os cálculos das validações foram desenvolvidos pela biblioteca de programação Numpy.

2.4 Estudo de caso

Os resultados obtidos a partir da ferramenta GeoPatterns foram avaliados utilizando uma ortoimagem com resolução espacial de 15 cm obtida utilizando uma câmara Sony de 36 megapixel, modelo ILCE-7R, acoplada ao Veículo Aéreo Não Tripulado (VANT) Echar 20B. Essa câmara compreende bandas do azul (B1 – 370 a 520 nm), do verde (B2 – 470 a 570 nm) e do infravermelho próximo (B3 - 670 a 770 nm). O voo foi realizado sobre 73,15 hectares da Estação Experimental da Universidade Federal do Rio Grande Sul (UFRGS), com uma sobreposição entre faixas de 80% e entre fotos de 60%. A ortoimagem foi processada no programa PhotoScan, conforme o seguinte fluxo de trabalho: entrada dos dados auxiliares (atitude da aeronave, posição espacial e calibração da câmara), alinhamento das imagens (pontos homólogos e calibração das

cores do brilho), otimização do alinhamento, determinação da nuvem de pontos densa, triangulação, exportação da ortoimagem e do Modelo Digital de Elevação (DEM) (Agisoft, 2016).

Para a segmentação, foram testados limiares de similaridade de 0,1 a 0,9, variando 0,1, e, para o tamanho mínimo dos objetos, foram avaliados os valores de 100 a 500, variando 50. As amostras de treinamento foram geradas por meio de uma grade regular, com equidistâncias de 25 metros, totalizando 825 pontos. Para as amostras de validação, foram gerados 1000 pontos aleatórios independentes dos dados de treinamento. A atribuição das classes desses pontos ocorreu por meio da interpretação da ortoimagem. Para isso, foram consideradas as seguintes classes de cobertura e uso da terra: Pastagem (PA), Resteva (RE), Solo Úmido (SU), Água (AG), Água Turva (AT), Banhado (BA) e Campo (CA). O conjunto de dados foi composto pelas seguintes características: espectrais, texturais e elevações do terreno, conforme Tabela 1. Para cada objeto geográfico das segmentações, foram calculadas as médias e os desvios padrão das características.

Tipo de característica	Características	Referências
Espectral	- Médias (M) e Desvios Padrão (DP) dos valores das bandas azul, verde e infravermelho próximo para os objetos; (B1M, B1DP, B2M, B2DP, B3M e B3DP); - Médias (M) e Desvios Padrão (DP) dos valores das razões entre as bandas para os objetos (B3B1M, B3B1DP, B3B2M, B3B2DP, B2B1M, B2B1DP);	(LALIBERTE & RANGO, 2011)
Texturais	- Médias das texturas extraídas pela <i>Gray Level Cooccurrence Matrix</i> , para os ângulos 0°, 45°, 90° e 135°. Posteriormente, nos quais são: <i>Angular Second Moment</i> (ASM e ASM_DP), <i>Correlation</i> (Corr e Corr_DP), <i>Entropy</i> (Ent e Ent_DP), <i>Contrast</i> (Cont e Cont_DP), <i>Sum Average</i> (SA e SA_DP), <i>Difference Entropy</i> (DE e DE_DP), <i>Sum Entropy</i> (SE e SE_DP), <i>Variance</i> (VAR e VAR_DP), <i>Inverse Difference Moment</i> (IDM e IDM_DP), <i>Difference Variance</i> (DV e DV_DP), <i>Sum Variance</i> (SV e SV_DP), <i>Information Measures of Correlation</i> (IMC e IMC_DP) e <i>Maximal Correlation Coefficient</i> (MCC e MCC_DP);	(HARALICK, SHANMUGA & DINSTEN, 1973; LALIBERTE & RANGO, 2009)
Elevação	Média (M) e Desvio Padrão (DP) do Modelo Digital de Elevação para os objetos (MDE e MDEDP)	

Tabela 1 - Conjunto de dados composto pelas seguintes características: espectrais, texturais e elevações do terreno.

Os parâmetros número de árvores (estimadores) e a máxima profundidade da árvore do método *Random Forest* foram avaliados com valores de 5 até 50, variando 5. Para o k-NN, foram considerados os valores de k entre 1 a 12, variando 1. As métricas das distâncias são variantes de Minkowski, em que: Manhattan (expoente = 1), Euclidiana (expoente = 2) e Minkowski (expoente

= 3). Também foram avaliados os pesos das distâncias de maneira uniforme e pelo inverso das distâncias.

3 RESULTADOS

3.1 Automatização e interface gráfica do programa GeoPatterns

A interface gráfica da ferramenta *Segmentation* – GRASSGIS é apresentada na Figura 2. A aba *Input* possibilita que o usuário informe a imagem a ser segmentada, Figura 2a. A segmentação disponível no GRASS-GIS depende de alguns parâmetros que estão disponíveis para configuração na aba *Parameters*, Figuras 2b e 2c. Os parâmetros limiar da similaridade (*Similarity threshold*) e o tamanho mínimo do objeto (*Minimum Object Size*) podem ser avaliados em intervalos de valores. O usuário informa o início, o final e o passo da avaliação. Como resultado, são geradas segmentações com diferentes valores para esses parâmetros. Como métodos de cálculos da similaridade (*Similarity calculation method*), estão disponíveis a distância Euclidiana e Manhattan.

Também pode ser informado pelo usuário o total de uso de memória (*Amount of memory to use*) e o número máximo de iterações (*Maximum number iterations*), Figura 2c. Quanto maior o total de uso de memória, menos custosa será a segmentação. Já para o número máximo de iterações, maiores valores resultam em segmentações mais custosas, visto que serão avaliados mais grupos de pixels sementes no crescimento das regiões (objetos geográficos).

Os pixels sementes podem ser gerados pelo usuário e inseridos na opção *Input raster map with starting seeds*, Figura 2c. Caso a imagem com os pixels sementes não seja informada (opção *None*), o GRASS-GIS inicia pixels sementes de forma aleatória. O parâmetro *Input bounding/constraining raster map* possibilita que o usuário insira um raster com os limites dos objetos geográficos, a opção *None* desconsidera esse parâmetro na segmentação. A aba *Output*, Figura 2d, possibilita que usuário informe o local de saída das segmentações. Nesse local, são geradas três pastas, uma com as segmentações no formato raster, uma no formato *shapefile* e outra com a qualidade das segmentações. Na área de texto, são apresentadas as etapas dos processamentos.

A interface gráfica da ferramenta *Segmentation* - GRASSGIS torna amigável ao usuário o processo de configuração da segmentação. As automatizações referentes às leituras, às escritas e às avaliações dos parâmetros da segmentação tornam essa etapa menos morosa.

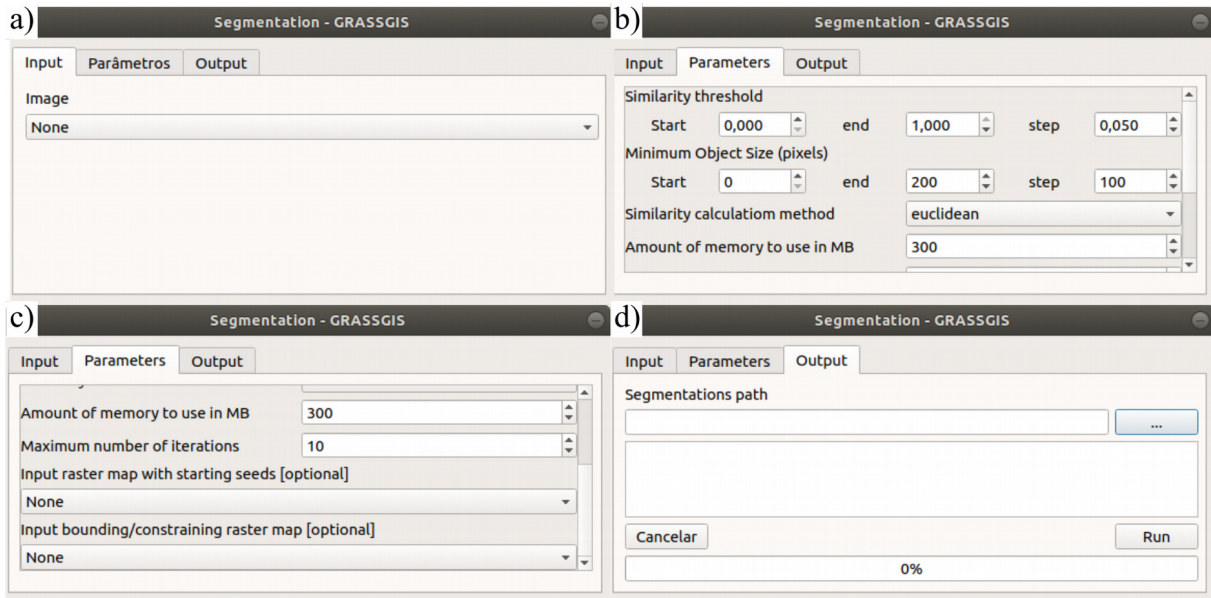


Figura 2 – Interface gráfica da segmentação: a) *Input*; b e c) *parameters*; d) *output*.

A interface gráfica da ferramenta *Sampling – Zonal Statistics* é apresentada na Figura 3. Na aba *Input*, o usuário informa o local das características e das segmentações no formato *shapefile*. A ferramenta realiza a leitura de cada segmentação e, para cada objeto geográfico, são calculadas estatísticas das características. Na aba *Parameters*, Figura 3b, o usuário pode selecionar as seguintes estatísticas: *Sum*, *Mean*, *Median*, *Standard desviation*, *Minimum*, *Maximum*, *Range*, *Minority*, *Majority* e *Variety*.

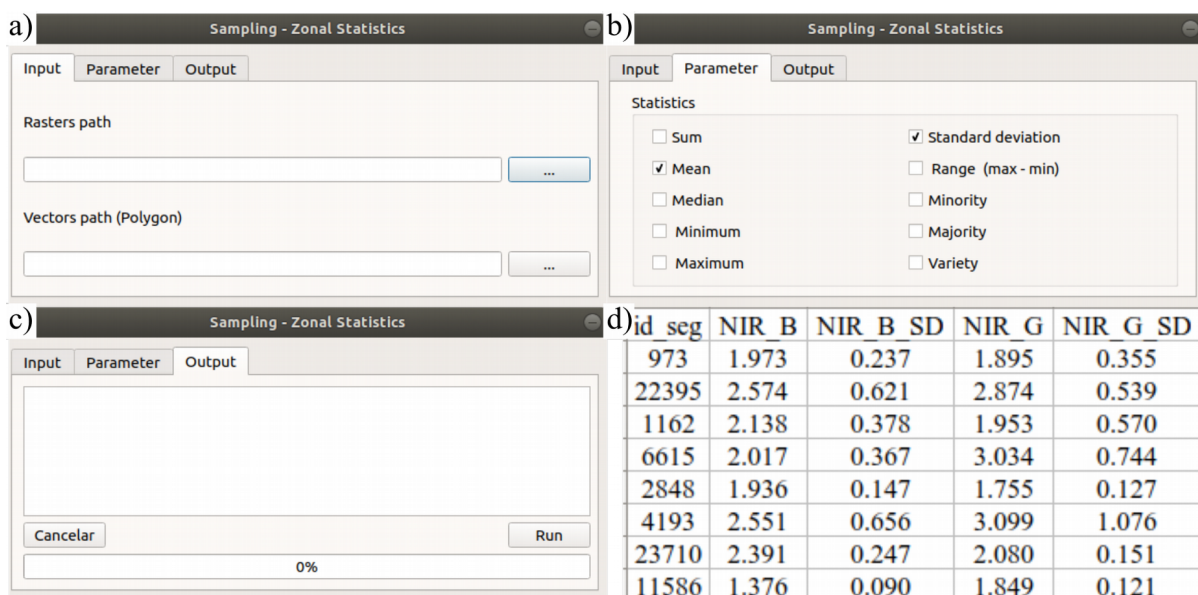


Figura 3 – Interface gráfica da *Sampling*: a) *Input*; b) *parameters*; c) *output*; d) tabela do conjunto de dados.

Na aba *Output*, Figura 3c, não há saídas para serem informadas, pois as estatísticas das características são inseridas nas segmentações de entrada, originando os data set. Na área de texto, são informadas as etapas dos processamentos. A Figura 3d ilustra a tabela do conjunto de dados resultante da ferramenta *Sampling – Zonal Statistics*, com as estatísticas das características para os objetos geográficos. A coluna com o identificador da segmentação não é considerada como característica no momento da classificação.

O processo de amostrar várias segmentações e características para gerar o conjunto de dados foi mais eficiente com a ferramenta *Sampling*, uma vez que o usuário informa os locais dos arquivos, e a ferramenta automaticamente gera os conjuntos de dados.

A interface gráfica do *Random Forest* está ilustrada na Figura 4. Na aba *Input*, o usuário deve informar as amostras de treinamento e de validação, como os campos das tabelas que representam as classes de cada amostra. Também é necessário inserir o local onde estão os conjuntos de dados gerados na etapa de amostragem. A ferramenta realiza a leitura de cada conjunto de dados e das amostras e seleciona as características da tabela do conjunto de dados que interseccionam com as amostras de treinamento e de validação.

Com as amostras geradas, são avaliadas as classificações com diferentes valores para os parâmetros. Na aba *Parameters*, Figura 4b, os valores do número de árvores (*Trees*) e máxima profundidade da árvore (*Depth*), como o critério de divisão, podem ser informados pelo usuário. O número de árvores e a máxima profundidade da árvore são informados em intervalos de valores. O usuário informa o início, o fim e o passo que serão considerados nas avaliações das classificações. Como critério de divisão (*function to measure the quality of a split*) pode ser selecionado o índice gini ou a entropia.

Habilitando a opção *Apply classification*, a ferramenta classifica o conjunto de dados com os valores dos parâmetros que resultaram na maior acurácia. A opção *Run terminal commands* propicia a execução das avaliações das classificações por meio do terminal do sistema operacional. Essa opção pode ser utilizada quando não for possível a integração do Scikit-Learn com o QGIS3.

Como resultados, são obtidas as avaliações das classificações, armazenadas em um arquivo texto, e o *shapefile* da classificação mais acurada, Figura 4c. As avaliações das classificações dos conjuntos de dados estão ilustradas na Figura 4d. Neste arquivo com as avaliações, estão armazenados os nomes dos conjuntos de dados (*Data set*), os parâmetros do número de árvores (*Trees*) e da máxima profundidade da árvore (*Depth*), bem como os valores das acurácias. No final do arquivo, são inseridas informações sobre o conjunto de dados mais acurado, a matriz de confusão e as relevâncias das características.

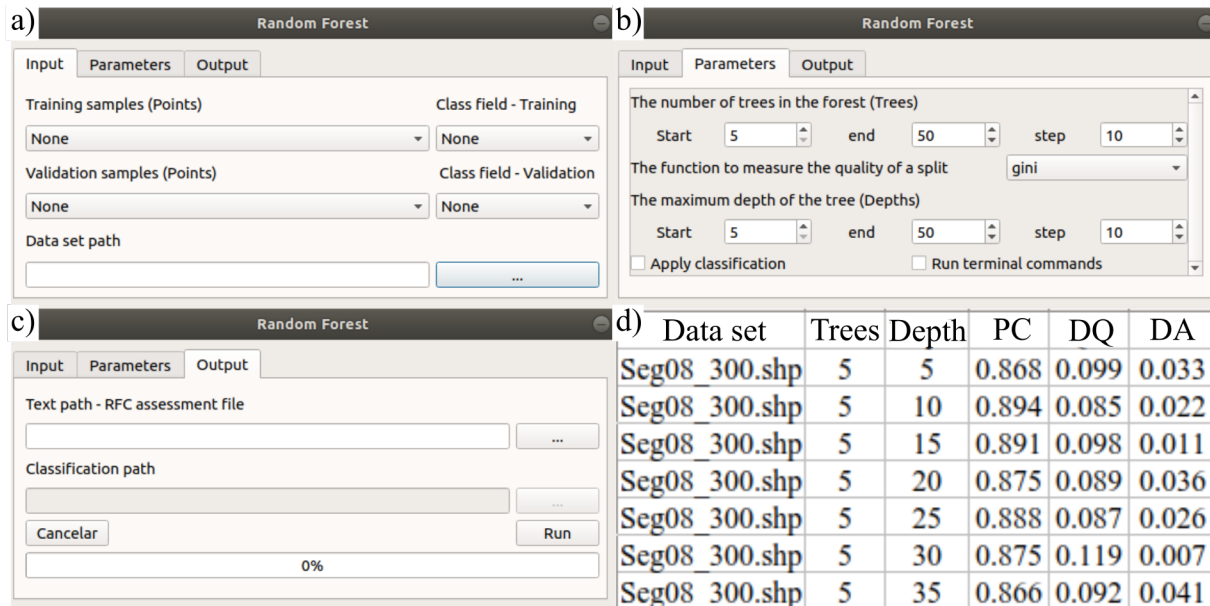


Figura 4 – Interface gráfica do método *Random Forest*: a) *Input*; b) *Parameters*; c) *Output*; d) Avaliação das classificações.

A ferramenta do método k-NN está apresentada na Figura 5. Como entrada, devem ser inseridas as amostras de treinamento e de validação, além dos respectivos campos que representam a coluna com os valores das classes. Também deve ser inserido o local dos conjuntos de dados gerados na etapa de amostragem, Figura 5a. A ferramenta está otimizada para realizar a leitura dos conjuntos de dados e selecionar as características da tabela por meio da intersecção com as amostras de validação e de treinamento, possibilitando, assim, as avaliações das classificações do método k-NN.

Os parâmetros considerados nas avaliações estão apresentados na Figura 5b. O número de vizinhos mais próximos (k) pode ser configurado com intervalo de valores para análise, sendo necessário inserir início, fim e o passo. Como métrica de distâncias, podem ser informadas: Manhattan (expoente = 1), Euclidiana (expoente = 2), Chebyshev ou todas as métricas no mesmo processamento. O usuário também tem a possibilidade de avaliar os pesos das distâncias de maneira uniforme (*Uniform*) ou pelo inverso das distâncias (*Inverse distance*). A classificação mais acurada é exportada se o usuário habilitar a opção *Apply classification*. Caso não seja possível a integração da biblioteca Scikit-Learn com QGIS3, a opção *Run terminal commands* possibilita as avaliações das classificações pelo terminal do sistema operacional.

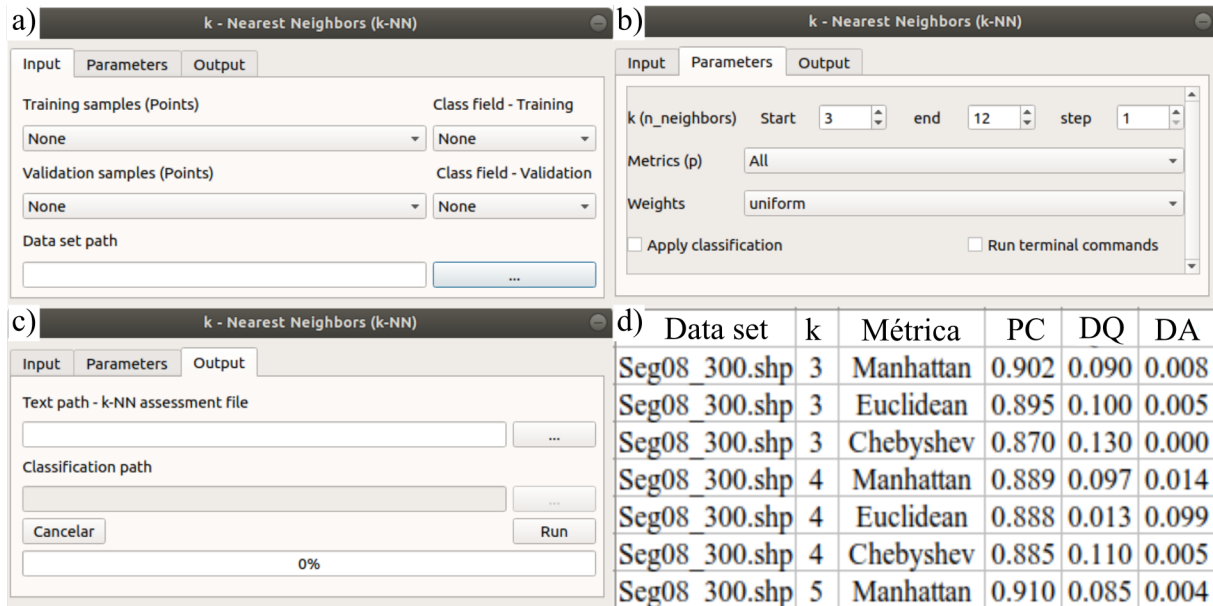


Figura 5 – Interface gráfica do método k-NN: a) *Input*; b) *Parameters*; c) *Output*; e d) Avaliação das classificações.

As saídas dessa ferramenta são os locais do arquivo texto com as avaliações e o *shapefile* com a classificação mais acurada, Figura 5c. As avaliações das classificações pelo método k-NN podem ser visualizadas na Figura 5d, em que estão apresentados os conjuntos de dados, o número de vizinhos (k), a métrica de distância e as acurácias das classificações (PC, DQ e DA). No final do arquivo com as avaliações das classificações, são informados o conjunto de dados, os parâmetros do método k-NN e a matriz de confusão para a classificação mais acurada.

A interface gráfica desenvolvida para a ferramenta GeoPatterns tornou amigável os processos de amostragem, de segmentação e de classificação dos objetos, possibilitando avaliações dos parâmetros por meio de intervalos de valores, além de considerar vários conjuntos de dados no momento da classificação. O desenvolvimento do GeoPatterns foi realizado com programas e bibliotecas de programação gratuitas, tornando-o uma ferramenta automatizada e sem custo aos geocientistas.

3.2 Estudo de caso

As segmentações da ortoimagem foram realizadas na ferramenta *Segmentation* do programa GeoPatterns. De posse das segmentações, as características foram amostradas com a ferramenta *Sampling*, originando os conjuntos de dados.

As avaliações das classificações dos conjuntos de dados para os métodos *Random Forest* e *k-NN* estão apresentadas na Figura 6. Para o método *Random Forest*, o conjunto de dados mais acurado foi obtido com limiar de similaridade igual a 0.1 e TMO igual a 400.

Os valores de PC para esse conjunto de dados e para os parâmetros do método *Random Forest* estão ilustrados na Figura 6a. As menores acurácias foram obtidas para valores de profundidade menores que 10 e número de árvores iguais a 5. O maior valor de PC foi obtido para profundidade igual a 20 e número de árvores igual a 35, resultando em um PC igual a 94,0%.

Para o método *k-NN*, o conjunto de dados mais acurado foi obtido com limiar de similaridade igual a 0,9 e TMO igual a 500. Na Figura 6b, estão apresentadas as acurácias desse conjunto de dados para os parâmetros do *k-NN*.

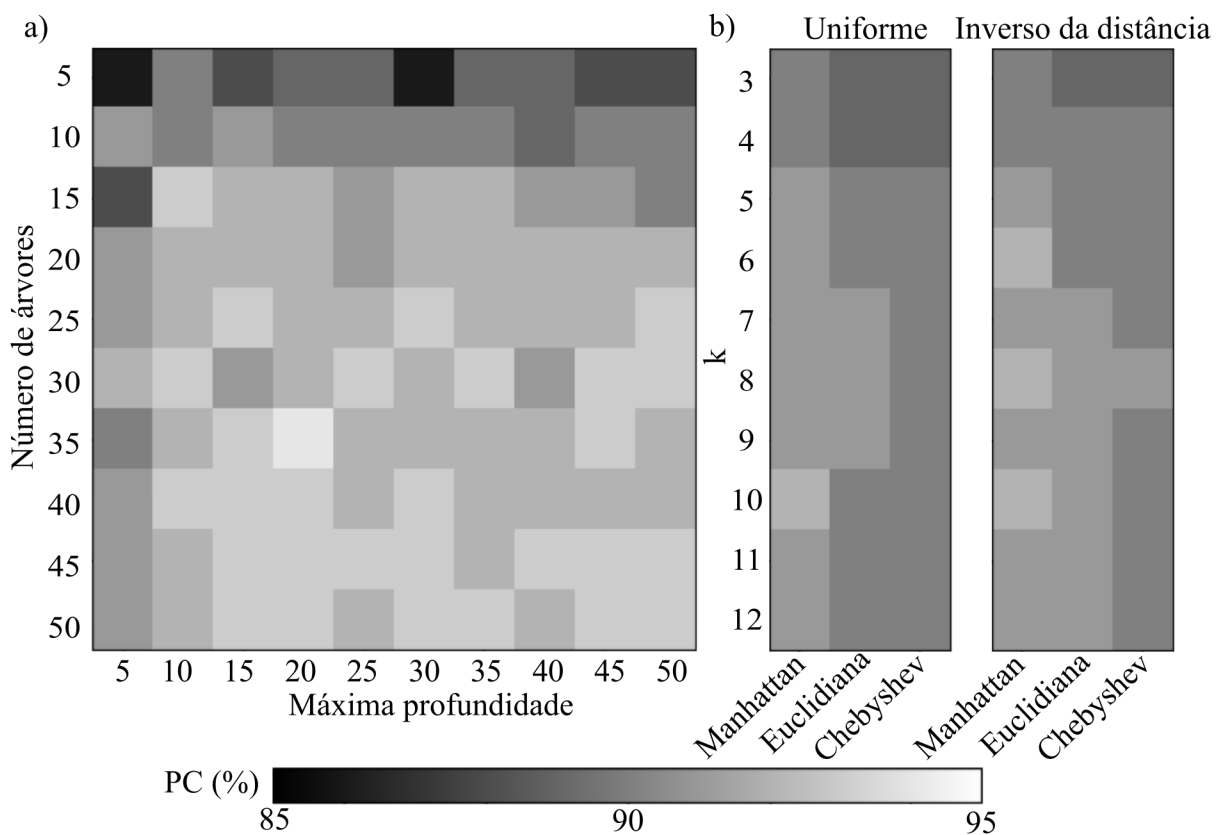


Figura 6 – Valores de PC (%) para os parâmetros dos métodos: a) RF; b) k-NN.

Os maiores valores das acurácias foram obtidas com *k* maiores que 4, métrica Manhattan e, para os dois métodos de pesos, o uniforme e o inverso da distância, que resultaram em valores de PC superiores a 90,0%.

A maior acurácia para o método *k-NN* foi obtida com *k* igual a 8, métrica Manhattan e inverso da distância, alcançando um valor de PC igual a 92,3%. O cálculo do peso pelo inverso da distância aumenta a influência das amostras mais próximas e diminui das amostras mais distantes,

mostrando-se como uma alternativa para melhorar o desempenho da classificação baseada em objetos.

Por meio do teste de proporção obtido com as acurácias dos melhores casos dos métodos de classificação (*Random Forest* = 94,0%; k-NN = 92,3%), foi alcançado um Z calculado igual a 1,5. Com isso, aceitamos a hipótese nula, ou seja, as diferenças das acurácias não são estatisticamente significativas ao nível de significância de 5%.

As relevâncias das características obtidas pelo método *Random Forest*, que resultaram em uma acurácia igual a 94,0%, estão apresentadas na Figura 7. A maioria das características espectrais resultaram em relevâncias superiores a 3,0%, em que a média da banda B3 obteve uma relevância de 10,0%, e a menor foi obtida pelo desvio padrão da razão entre as banda B3 e B2 (B3B2DP), resultando em uma relevância de 1,7%.




Figura 7 – Relevâncias das características obtidas pelo método *Random Forest*.

Ahmed et al. (2017) avaliaram câmaras multiespectrais e uma convencional (RBG) na classificação de diferentes espécies de vegetação em áreas agrícolas e em uma floresta mista. Os autores obtiveram maiores relevâncias para a banda do infravermelho, utilizando a câmara multiespectral e para texturas com a câmara convencional.

A maior parte das relevâncias das texturas apresentou valores menores que 3,0%, com a maior relevância para a característica SE (7,3%), MCC e MCC_DP resultaram em relevâncias iguais a 0,0%, reduzindo a dimensionalidade do conjunto de dados.

Mesmo com variações do terreno menores que 10 metros, as características MDE e MDE_DP obtiveram relevâncias de 2,7% e de 1,0%, respectivamente. Laliberte & Rango (2009) aumentaram o desempenho do mapeamento de espécies de pastagens utilizando características texturais.

Ma et al. (2017) avaliaram métodos de seleção de características na classificação baseada em objetos de imagens obtidas por VANT, considerando os classificadores *Random Forest* e SVM. Os autores relataram que a seleção das características foi uma etapa crucial para o bom desempenho da classificação baseada em objetos e que deve ser realizada antes da classificação.

Na Figura 8, estão apresentadas a ortoimagem, Figura 8a, e as classificações mais acuradas pelo método *Random Forest*, Figura 8b, e do k-NN, Figura 8c. Ambos os métodos de classificação apresentaram uma boa correspondência com a ortoimagem.

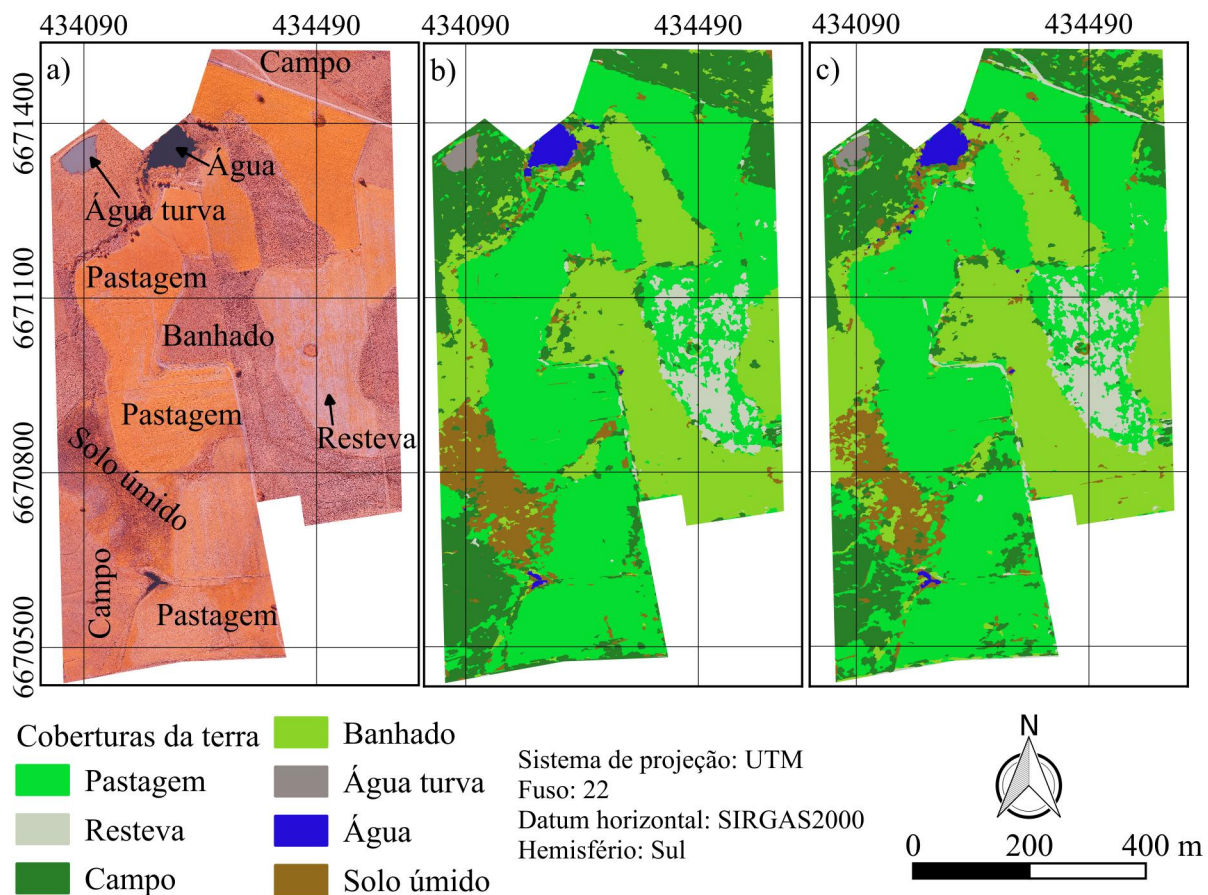


Figura 8 – a) ortoimagem; classificações baseadas em objetos pelos métodos: a) *Random Forest*; e b) k-NN.

A classe Pastagem apresenta variações relacionadas a diferentes etapas do ciclo fenológico, no entanto, foram bem discriminadas pelos métodos. Classes que possuem uma menor ocorrência

na área, como Água turva, Água, Resteva e Solo úmido, também foram classificadas corretamente, entretanto, a classe Solo úmido foi subestimada pelo método k-NN.

A classe Banhado apresenta diferenças na sua composição, com vários tipos de vegetação e em distintos estágios de senescência. Os métodos *Random Forest* e k-NN aprenderam o comportamento dessa classe, possibilitando a discriminação do Banhado em relação às demais classes. Contudo, para ambos os classificadores, foram encontradas algumas inconsistências nos limites entre as classes Pastagem e Banhado.

As matrizes de confusão obtidas da comparação das classificações mais acuradas dos métodos *Random Forest* e k-NN, com as 1000 amostras de validação (dados de referência), estão apresentadas na Tabela 2. Ambos os métodos acertaram 100% dos dados de referência das classes TW e SU. *Random Forest* e k-NN também obtiveram o valor de PP igual a 96,2% para a classe PA e apresentaram as maiores confusões com a classe CA. A classe PA localizada ao sul da ortoimagem apresenta um comportamento espectral semelhante com a classe CA, o que pode ser o motivo das confusões. Mesmo para a classe BA, uma das mais complexas, os acertos alcançaram os valores de PP iguais a 92,3% para *Random Forest* e 96,5% para k-NN, com algumas confusões entre as BA e CA.

Classificação	Amostras de validação (dados de referência)															
	<i>Random Forest</i>								k-NN							
	PA	RE	CA	BA	AT	AG	SU	PU	PA	RE	CA	BA	AT	AG	SU	PU
PA	418	14	9	1	0	0	1	94,0	418	7	22	0	0	0	3	92,3
RE	2	70	0	0	0	0	0	97,1	3	74	0	0	0	0	0	95,9
CA	9	0	150	15	0	0	1	83,3	8	0	135	5	0	0	1	89,6
BA	3	0	7	220	0	0	3	94,1	3	3	9	230	0	0	8	90,0
AT	0	0	0	0	4	0	0	100	0	0	0	0	4	0	0	100
AG	0	0	0	0	0	11	0	100	0	0	0	0	0	11	0	100
SU	2	0	2	1	0	0	54	90,7	2	0	2	3	0	0	47	85,1
PP	96,2	80,0	88,0	92,3	100	100	90,7		96,2	86,5	75,5	96,5	100	100	74,5	

Tabela 2 – Matrizes de confusão.

As maiores confusões foram encontradas para as classes RE, CA e SU. *Random Forest* obteve um valor de PP igual a 80,0% para a classe RE, e k-NN apresentou um valor de PP igual a 86,5%, demonstrando confusões com a classe PA. A classe RE ocorre em áreas que o dossel da PA ainda não cobriu totalmente o solo. Para a classe CA, os valores de PP foram de 88,0% e de 75,0%. Valores mais baixos para essas classes podem estar relacionados com as semelhanças de textura

com a classe BA e espectral com a classe PA, dificultando sua discriminação em alguns locais na ortoimagem.

Para o método k-NN, a classe SU apresentou as maiores confusões, resultando em um PP igual a 74,5%. Como apresentado na Figura 8c, o método subestimou essa classe, confundindo SU com BA. *Random Forest* também confundiu SU com BA, mas em menor proporção, obtendo um valor de PP igual a 90,7%. A confusão nessa classe fez com que o método k-NN resultasse em uma acurácia global de 91,9%, menor que *Random Forest*, em que o resultado foi de 92,7%.

Com o programa GeoPatterns foi possível gerar 45 segmentações, amostrar 40 características, avaliar 36 pares de parâmetros para o método *Random Forest* e 72 conjuntos de parâmetros para o método k-NN, totalizando 4860 classificações. Todas essas avaliações das classificações foram realizadas de forma automatizada e com ferramentas amigáveis que contemplam as etapas de segmentação, de amostragem e de classificação dos objetos geográficos.

Com as saídas do GeoPatterns, foi possível obter o conjunto de dados mais acurado no formato *shapefile*, os valores das acurácias e as matrizes de confusão para cada método de classificação. Também foram obtidas as relevâncias das características para a classificação mais acurada do método *Random Forest*.

Esses resultados evidenciam a eficiência do programa GeoPatterns e as ferramentas utilizadas para seu desenvolvimento, uma vez que foram avaliadas várias combinações de segmentações e de parâmetros das classificações, obtendo, ainda, acurácias superiores a 90,0%.

4 CONCLUSÕES

O programa GeoPatterns, desenvolvido neste trabalho, possibilitou uma integração de técnicas não paramétricas de reconhecimento de padrões e OBIA. Permitiu também uma automatização dos processos de segmentação, amostragem e classificação dos objetos geográficos. A interface gráfica tornou mais amigável a aplicação dessa metodologia em imagens com resolução espacial submétrica obtidas por VANT. Como os programas e as bibliotecas de programação necessárias para a utilização do GeoPatterns são gratuitas, os geocientistas podem usufruir das ferramentas sem custos.

As técnicas não paramétricas de reconhecimento de padrões *Random Forest* e k-NN apresentaram acurácias elevadas na classificação dos objetos, com PC superiores a 90,0%. O método *Random Forest* possibilitou a seleção das características mais relevantes e a redução da dimensionalidade do conjunto de dados. A banda do infravermelho próximo e a textura *Sum*

Entropy foram as características mais relevantes na discriminação das classes de cobertura e do uso da terra.

Futuros desenvolvimentos para o programa GeoPatterns podem ocorrer em relação à extração de características geométricas e contextuais para os objetos geográficos, além do acréscimo de métodos de regressão.

REFERÊNCIAS

- AGISOFT. 2016 “Support Tutorials.” Acessado em janeiro de 2017. <http://www.agisoft.com/support/tutorials/intermediate-level>
- AHMED, O. S. et al. Hierarchical land cover and vegetation classification using multispectral data acquired from an unmanned aerial vehicle. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2037–2052, 19 maio 2017.
- BLASCHKE, T. et al. Geographic Object-Based Image Analysis – Towards a new paradigm. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 180–191, 1 jan. 2014.
- BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.
- ESPINDOLA, G. M. et al. Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation. **International Journal of Remote Sensing**, v. 27, n. 14, p. 3035–3040, 20 jul. 2006.
- FRANKLIN, S. E.; AHMED, O. S. Deciduous tree species classification using object-based analysis and machine learning with unmanned aerial vehicle multispectral data. **International Journal of Remote Sensing**, v. 39, n. 15–16, p. 5236–5245, 18 ago. 2018.
- GU, J.; CONGALTON, R.; PAN, Y. The Impact of Positional Errors on Soft Classification Accuracy Assessment: A Simulation Analysis. **Remote Sensing**, v. 7, n. 1, p. 579–599, 7 jan. 2015.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural Features for Image Classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. SMC-3, n. 6, p. 610–621, nov. 1973.
- HELLESEN, T.; 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, 28 jan. 2013.
- LALIBERTE, A. S. et al. Multispectral Remote Sensing from Unmanned Aircraft: Image Processing Workflows and Applications for Rangeland Environments. **Remote Sensing**, v. 3, n. 11, p. 2529–2551, 22 nov. 2011.
- LALIBERTE, A. S.; RANGO, A. Texture and Scale in Object-Based Analysis of Subdecimeter Resolution Unmanned Aerial Vehicle (UAV) Imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 761–770, mar. 2009.
- LALIBERTE, A. S.; 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, 15 jan. 2011.
- MA, L. et al. Evaluation of Feature Selection Methods for Object-Based Land Cover Mapping of Unmanned Aerial Vehicle Imagery Using Random Forest and Support Vector Machine Classifiers. **ISPRS International Journal of Geo-Information**, v. 6, n. 2, p. 51, 18 fev. 2017.

OOI, H.-L.; NG, S.-C.; LIM, E. ANO Detection with K-Nearest Neighbor Using Minkowski Distance. **International Journal of Signal Processing Systems**, p. 208–211, 2013.

PANDE-CHHETRI, R. et al. Object-based classification of wetland vegetation using very high-resolution unmanned air system imagery. **European Journal of Remote Sensing**, v. 50, n. 1, p. 564–576, 8 jan. 2017.

PONTIUS, R. G. Quantification error versus location error in comparison of categorical maps. **Photogrammetric Engineering & Remote Sensing**, v. 66, 2000.

PONTIUS, R. G.; MILLONES, M. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, v. 32, n. 15, p. 4407–4429, 10 ago. 2011.

QIAN, Y. et al. Comparing Machine Learning Classifiers for Object-Based Land Cover Classification Using Very High Resolution Imagery. **Remote Sensing**, v. 7, n. 1, p. 153–168, 24 dez. 2014.

TEODORO, A. C.; ARAÚJO, R. Exploration of the OBIA methods available in SPRING noncommercial software to UAV data processing. (U. Michel, K. Schulz, Eds.). **International Society for Optics and Photonics**, 10 out. 2014. Disponível em: <<http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.2066468>>. Acesso em: 5 nov. 2018.

4 CONCLUSÕES GERAIS

OBIA possibilita a extração de características adicionais, como contextuais e geométricas, gerando um conjunto de dados de alta dimensionalidade. A seleção das características mais relevantes é uma etapa importante dessa metodologia. O método de classificação k-NN tem dificuldade em lidar com conjunto de dados de alta dimensionalidade e com a sobreposição dos valores das características. A classificação pelo k-NN também depende da seleção do k vizinhos mais próximos: k com baixos valores são influenciados pelos ruídos dos dados e k com altos valores podem considerar amostras de classes distintas.

O método *Iterative K-Nearest Neighbors* (IKNN), proposto neste trabalho, trata essas limitações do k-NN utilizando *Gini Importances* (GI) para selecionar as características mais relevantes e a taxa de acerto da classificação para selecionar o número de k mais apropriado.

Utilizar o GI como peso das características permitiu que o método IKNN reduzisse em 8% a dimensionalidade do conjunto de dados e tratasse a sobreposição entre os valores das características. Experimentos utilizando o método proposto com limiar de acerto da classificação igual a 60% resultaram em uma proporção correta (PC) de 90%. Tais experimentos resultaram também em uma acurácia superior aos métodos SVM e k-NN, que obtiveram acurácias iguais a 88,5% e a 76,2%, respectivamente.

A pós-classificação tem como objetivo refinar uma classificação para melhorar seu desempenho. As pós-classificações utilizadas em imagens obtidas por VANT consideram a classificação baseada em pixel. Essas imagens apresentam uma alta variabilidade espectral, o que dificulta a classificação baseada em pixel. Neste trabalho, os dois métodos de pós-classificação propostos consideram o contexto espacial dos objetos.

O método Votação dos Objetos Vizinhos (VOV) avalia a segmentação e a classificação baseada em objetos. O método Quantificação das Fronteiras dos Objetos (QFO) considera apenas a classificação baseada em objetos.

A pós-classificação VOV aumentou as acurácias do mapeamento da cobertura e do uso da terra de 92,5% para 95,7%, quando o Tamanho Mínimo do Objeto (TMO) recebeu valores maiores que 7000. O método de pós-classificação QFO resultou em um acréscimo de 4,5% nas acurácias, passando de 92,5% para 97,0%, quando TMO recebeu valores superiores a 9400. Os métodos VOV e QFO também melhoraram a correspondência da classificação baseada em objeto com a ortoimagem, diminuindo o efeito “sal e pimenta”.

Para este estudo, o método Votação Baseada em Objetos (VBO) resultou em um decréscimo no desempenho da pós-classificação da cobertura e do uso da terra por meio de imagens com resolução espacial submétrica obtidas por VANT. Isso ocorreu devido aos erros de

classificação das classes Banhado e Solo Úmido na abordagem baseada em pixel, resultando em uma errônea pós-classificação dessas classes pelo método VBO.

Técnicas não paramétricas de reconhecimento de padrões e OBIA foram utilizadas com sucesso na classificação da cobertura e do uso da terra por meio de imagens de resolução espacial submétrica obtidas por VANT. Contudo, as etapas de segmentação e classificação demandam uma avaliação dos parâmetros ótimos, com intuito de evitar um superajustamento dos modelos e melhorar seu desempenho da classificação.

Desenvolvimentos de rotinas automatizadas e de interfaces gráficas poderiam propiciar a seleção dos parâmetros mais apropriados e facilitar a utilização dessa metodologia. A programação de algoritmos automatizados que integram métodos não paramétricos de reconhecimento de padrões e OBIA e o desenvolvimento de uma interface amigável para essa integração originaram o programa GeoPatterns.

GeoPatterns foi avaliado em um estudo de caso com imagens obtidas por VANT. O programa proporcionou uma automatização dos processos de segmentação, amostragem e classificação dos objetos geográficos. A interface gráfica tornou mais amigável a aplicação de técnicas não paramétricas e da OBIA na classificação baseada em objetos da cobertura e do uso da terra por meio de imagens obtidas por VANT. Além disso, facilitou a seleção dos parâmetros mais apropriados da segmentação e da classificação, bem como expandiu a acessibilidade dessa metodologia aos geocientistas.

Os métodos *Random Forest* e k-NN apresentaram acurácias elevadas na classificação baseada em objetos com PC iguais a 94,0% e a 92,3%, respectivamente. *Random Forest* ainda possibilitou a seleção das características mais relevantes e a redução da dimensionalidade do conjunto de dados.

Considerando os resultados obtidos, assume-se como verdadeira a hipótese de que a aplicação de técnicas não paramétricas de reconhecimento de padrões e Análise de Imagens Baseada em Objetos possibilitou obter mapeamentos acurados da cobertura e do uso da terra por meio de imagens obtidas por VANT.

OBIA permitiu um pré-processamento das imagens obtidas por VANT, proporcionando a redução da variabilidade espectral das imagens e a extração das características geométricas e contextuais. Técnicas não paramétricas de reconhecimento de padrões, como *Random Forest* e Árvore de Decisão, possibilitaram a seleção das características mais relevantes, diminuindo a dimensionalidade do conjunto de dados e tratando as sobreposições entre os valores das características. As técnicas IKNN, k-NN, SVM e *Random Forest* obtiveram um elevado

desempenho na classificação baseada em objetos da cobertura e do uso da terra por meio de imagens obtidas por VANT.

A utilização de imagens obtidas por VANT na classificação da cobertura e do uso da terra vem crescendo exponencialmente. Nesse sentido, pesquisas relacionadas à seleção de características, ao entendimento da transferência de aprendizagem e do poder de generalização dos modelos ainda são necessárias. Estudos nessa linha possibilitariam o avanço dessa tecnologia, uma vez que modelos ajustados para uma determinada área poderiam ser replicados em outras condições semelhantes.

REFERÊNCIAS

- AHMED, O. S. et al. Hierarchical land cover and vegetation classification using multispectral data acquired from an unmanned aerial vehicle. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2037–2052, 19 maio 2017.
- AASEN, H. et al. Quantitative Remote Sensing at Ultra-High Resolution with UAV Spectroscopy: A Review of Sensor Technology, Measurement Procedures, and Data Correction Workflows. **Remote Sensing**, v. 10, n. 7, p. 1091, 9 jul. 2018.
- AKAR, Ö. Mapping land use with using Rotation Forest algorithm from UAV images. **European Journal of Remote Sensing**, v. 50, n. 1, p. 269–279, 16 jan. 2017.
- BELWARD, A. S.; SKØIEN, J. O. Who launched what, when and why; trends in global land-cover observation capacity from civilian earth observation satellites. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 103, p. 115–128, 1 maio 2015.
- BLASCHKE, T. et al. Geographic Object-Based Image Analysis – Towards a new paradigm. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 180–191, 1 jan. 2014.
- CÁNOVAS-GARCÍA, F.; ALONSO-SARRÍA, F. Optimal Combination of Classification Algorithms and Feature Ranking Methods for Object-Based Classification of Submeter Resolution Z/I-Imaging DMC Imagery. **Remote Sensing**, v. 7, n. 4, p. 4651–4677, 17 abr. 2015.
- CHABOT, D. et al. An Object-Based Image Analysis Workflow for Monitoring Shallow-Water Aquatic Vegetation in Multispectral Drone Imagery. **ISPRS International Journal of Geo-Information**, v. 7, n. 8, p. 294, 24 jul. 2018.
- CHAPMAN, S. et al. Pheno-Copter: A Low-Altitude, Autonomous Remote-Sensing Robotic Helicopter for High-Throughput Field-Based Phenotyping. **Agronomy**, v. 4, n. 2, p. 279–301, 17 jun. 2014.
- CHRISTIANSEN, P. et al. Automated Detection and Recognition of Wildlife Using Thermal Cameras. **Sensors**, v. 14, n. 8, p. 13778–13793, 30 jul. 2014.
- CROMMELINCK, S. et al. Review of Automatic Feature Extraction from High-Resolution Optical Sensor Data for UAV-Based Cadastral Mapping. **Remote Sensing**, v. 8, n. 8, p. 689, 22 ago. 2016.
- ESPINDOLA, G. M. et al. Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation. **International Journal of Remote Sensing**, v. 27, n. 14, p. 3035–3040, 20 jul. 2006.
- FENG, Q. et al. Urban Flood Mapping Based on Unmanned Aerial Vehicle Remote Sensing and Random Forest Classifier—A Case of Yuyao, China. **Water**, v. 7, n. 12, p. 1437–1455, 31 mar. 2015.
- FENG, Q.; LIU, J.; GONG, J. UAV Remote Sensing for Urban Vegetation Mapping Using Random Forest and Texture Analysis. **Remote Sensing**, v. 7, p. 1074–1094, 19 jan. 2015.

FRASER, B.; CONGALTON, R. Issues in Unmanned Aerial Systems (UAS) Data Collection of Complex Forest Environments. **Remote Sensing**, v. 10, n. 6, p. 908, 8 jun. 2018.

HADAVAND, A. et al. Using Pixel-Based And Object-Based Methods To Classify Urban Hyperspectral Features. **Geodesy and cartography**, v. 42, n. 3, p. 92–105, 22 set. 2016.

HARWIN, S.; LUCIEER, A. Assessing the Accuracy of Georeferenced Point Clouds Produced via Multi-View Stereopsis from Unmanned Aerial Vehicle (UAV) Imagery. **Remote Sensing**, v. 4, n. 6, p. 1573–1599, 2012.

HELLESEN, T.; 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, 28 jan. 2013.

HUANG, C.; DAVIS, L. S.; TOWNSHEND, J. R. G. An assessment of support vector machines for land cover classification. **International Journal of Remote Sensing**, v. 23, n. 4, p. 725–749, 25 jan. 2002.

KEDZIERSKI, M.; WIERZBICKI, D. Radiometric quality assessment of images acquired by UAV's in various lighting and weather conditions. **Measurement**, v. 76, p. 156–169, 1 dez. 2015.

LALIBERTE, A. S. . et al. Multispectral remote sensing from unmanned aircraft: Image processing workflows and applications for rangeland environments. **Remote Sensing**, v. 3, n. 11, p. 2529–2551, 2011.

LALIBERTE, A. S.; BROWNING, D. M.; 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, 1 abr. 2012.

LALIBERTE, A. S.; 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, 15 jan. 2011.

LI, M. et al. A systematic comparison of different object-based classification techniques using high spatial resolution imagery in agricultural environments. **International Journal of Applied Earth Observation and Geoinformation**, v. 49, p. 87–98, 1 jul. 2016.

LIEBISCH, F. et al. Remote, aerial phenotyping of maize traits with a mobile multi-sensor approach. **Plant Methods**, v. 11, n. 1, p. 9, 25 fev. 2015.

LOTTE, P. et al. UAV-based crop and weed classification for smart farming. **2017 IEEE International Conference on Robotics and Automation (ICRA)**. Anais...IEEE, maio 2017Disponível em: <<http://ieeexplore.ieee.org/document/7989347/>>. Acesso em: 4 nov. 2018

LUNA, I.; LOBO, A. Mapping Crop Planting Quality in Sugarcane from UAV Imagery: A Pilot Study in Nicaragua. **Remote Sensing**, v. 8, n. 6, p. 500, 14 jun. 2016.

MA, L. et al. Training set size, scale, and features in Geographic Object-Based Image Analysis of very high resolution unmanned aerial vehicle imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 14–27, 1 abr. 2015.

MA, L. et al. Evaluation of Feature Selection Methods for Object-Based Land Cover Mapping of Unmanned Aerial Vehicle Imagery Using Random Forest and Support Vector Machine Classifiers. **ISPRS International Journal of Geo-Information**, v. 6, n. 2, p. 51, 18 fev. 2017.

OOI, H.-L.; NG, S.-C.; LIM, E. ANO Detection with K-Nearest Neighbor Using Minkowski Distance. **International Journal of Signal Processing Systems**, p. 208–211, 2013.

PÁDUA, L. et al. UAS, sensors, and data processing in agroforestry: a review towards practical applications. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2349–2391, 19 maio 2017.

PANDE-CHHETRI, R. et al. Object-based classification of wetland vegetation using very high-resolution unmanned air system imagery. **European Journal of Remote Sensing**, v. 50, n. 1, p. 564–576, 8 jan. 2017.

PHIRI, D.; MORGENROTH, J. Developments in Landsat Land Cover Classification Methods: A Review. **Remote Sensing**, v. 9, p. 967, 19 setembro 2017.

PUISSANT, A.; ROUGIER, S.; STUMPF, A. Object-oriented mapping of urban trees using Random Forest classifiers. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 235–245, 1 fev. 2014.

QIAN, Y. et al. Comparing Machine Learning Classifiers for Object-Based Land Cover Classification Using Very High Resolution Imagery. **Remote Sensing**, v. 7, n. 1, p. 153–168, 24 dez. 2014.

SAMANIEGO, L.; SCHULZ, K. Supervised Classification of Agricultural Land Cover Using a Modified k-NN Technique (MNN) and Landsat Remote Sensing Imagery. **Remote Sensing**, v. 1, n. 4, p. 875–895, 9 nov. 2009.

SANZ-ABLANEDO, E. et al. Accuracy of Unmanned Aerial Vehicle (UAV) and SfM Photogrammetry Survey as a Function of the Number and Location of Ground Control Points Used. **Remote Sensing**, v. 10, n. 10, p. 1606, 9 out. 2018.

SIBARUDDIN, H. I. et al. UAV-based Approach to Extract Topographic and As-built Information by Utilising the OBIA Technique. **Journal of Geosciences and Geomatics**, Vol. 6, 2018, Pages 103-123, v. 6, n. 3, p. 103–123, 8 out. 2018.

TARABALKA, Y. et al. Segmentation and Classification of Hyperspectral Data using Watershed. IGARSS 2008 - 2008 **IEEE International Geoscience and Remote Sensing Symposium. Anais...IEEE**, 2008Disponível em: <<http://ieeexplore.ieee.org/document/4779432/>>. Acesso em: 5 nov. 2018TEODORO, A. C.; ARAÚJO, R. Exploration of the OBIA methods available in SPRING noncommercial software to UAV data processing. (U. Michel, K. Schulz, Eds.)**International Society for Optics and Photonics**, 10 out. 2014Disponível em:

<<http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.2066468>>. Acesso em: 5 nov. 2018.

TURNER, D.; LUCIEER, A.; WATSON, C. An Automated Technique for Generating Georectified Mosaics from Ultra-High Resolution Unmanned Aerial Vehicle (UAV) Imagery, Based on Structure from Motion (SfM) Point Clouds. **Remote Sensing**, v. 4, n. 5, p. 1392–1410, 14 maio 2012.

XIANG, H.; TIAN, L. Development of a low-cost agricultural remote sensing system based on an autonomous unmanned aerial vehicle (UAV). **Biosystems Engineering**, v. 108, n. 2, p. 174–190, 1 fev. 2011.

YANG, G. et al. Unmanned Aerial Vehicle Remote Sensing for Field-Based Crop Phenotyping: Current Status and Perspectives. **Frontiers in Plant Science**, v. 8, p. 1111, 30 jun. 2017.