

Análise de imagens baseada em objetos geográficos: comparação de regras de classificação da cobertura da terra

Geographic Object-Based Image Analysis: comparison of land cover classification rules

Agnes Silva de Araujo *, Alfredo Pereira de Queiroz **

* Programa de Pós-graduação em Gestão Urbana (PPGTU) da Pontifícia Universidade Católica do Paraná (PUCPR), agnes.araujo@pucpr.br

** Departamento de Geografia - FFLCH, Universidade de São Paulo, aqueiroz@usp.br

DOI: <http://dx.doi.org/10.5380/raega.v56i0.84710>

Resumo

Os níveis de automação do processo de classificação das imagens de satélite variam muito entre as diferentes pesquisas. Contudo, inúmeros trabalhos demonstraram que os procedimentos semiautomáticos, como a Análise de Imagens Baseada em Objetos Geográficos (GEOBIA), produzem melhores resultados. Este artigo tem como objetivo comparar os parâmetros de classificação desenvolvidos por quatro analistas distintos, que se basearam na mesma chave de interpretação, aplicados em duas cenas de Marília - SP. Visa avaliar o potencial de transferência das regras de classificação entre as diferentes áreas. Os resultados mostraram que os analistas optaram por diferentes: conjuntos de regras, atributos quantificáveis, limiares e níveis hierárquicos. No entanto, os índices *kappa* das classificações foram considerados muito bons. E, os conjuntos de regras produzidos por três analistas apresentaram elevada capacidade de transferência entre as cenas analisadas. Essa constatação ressalta a relevância de criar bibliotecas específicas para compartilhar os referidos procedimentos.

Palavras-chave:

classificação de imagens, Sensoriamento Remoto, GEOBIA, potencial de transferência.

Abstract

Automation levels for satellite image classification vary widely among different researches. However, numerous studies have shown that semi-automatic procedures, such as Geographic Object-Based Image Analysis (GEOBIA), produce better results. This paper aims to compare classification parameters developed by four different analysts, based on the same interpretation key applied to two scenes from Marília city - SP (Brazil). Thus, it aims to assess the potential for transferring classification rules between areas. Results showed that the analysts differed in option for set of rules, quantifiable attributes, thresholds, and hierarchical levels. Yet, the kappa indices of the classifications were deemed very good. Besides, three of the analysts produced sets of rules with

high transferability between the analyzed scenes. This finding highlights the relevance of creating specific libraries to share such procedures.

Keywords:

Image classification, Remote Sensing, GEOBIA, transferability potential.

I. INTRODUÇÃO

O uso dos modelos na Geografia se difundiu a partir da década de 1960 (FOTHERINGHAM; ROGERSON 2009). Um modelo pode ser considerado como a apresentação formal de uma teoria que usa elementos de lógica e matemática (HARVEY, 1974). Dentre as principais vantagens dos modelos, de acordo com Haggett e Chorley (1974), destacam-se as possibilidades de: acompanhar visualmente a lógica do fluxo de trabalho; automatizar a realização de tarefas recorrentes; adicionar complexidade ao modelo, vinculando submodelos ao modelo principal; reproduzir e compartilhar seu conteúdo.

Os modelos de uso e cobertura da terra desempenham papéis importantes no planejamento e na elaboração de políticas públicas. São ferramentas eficientes para apoiar a análise das causas, processos e consequências da interação do homem com o meio ambiente (TANG et al. 2009). Mapas de uso e cobertura da terra, desenvolvidos a partir de imagens de Sensoriamento Remoto, são muito utilizados na elaboração de diagnósticos ambientais e gestão territorial (LIU et al., 2017).

A classificação de imagens pode ser realizada de inúmeras formas, que variam entre a manual, como a fotointerpretação, até as automáticas, que adotam algoritmos de classificação. No entanto, segundo Francisco e Almeida (2012), as mais apropriadas para classificação de uso e cobertura da terra são as semiautomáticas, que integram o conhecimento e a intervenção humana aos algoritmos de classificação. As referidas classificações, no entanto, estão sujeitas a distintos níveis de subjetividade (GARDIN et al., 2011). Nesse contexto, esta pesquisa se justifica, e corrobora as observações de Mahdavi et al., (2018), na medida em que se considera que o compartilhamento de procedimentos e regras de classificação entre os analistas contribui para melhorar a sua qualidade. A pesquisa também colabora com os recentes esforços de investigação sobre a construção de bibliotecas de atributos quantificáveis de objetos geográficos, abordada por CHEN et al., (2018).

O objetivo deste artigo é avaliar as classificações semiautomáticas da cobertura da terra produzidas por quatro analistas diferentes, em duas cenas do município de Marília – SP, a partir de uma única chave de interpretação. As regras, os atributos quantificáveis, os limiares e os níveis hierárquicos utilizados nas classificações de imagens de satélite baseadas em objetos geográficos (GEOBIA) foram analisados de forma a

permitir a reflexão sobre o potencial de transferência das regras de classificação entre diferentes áreas de estudo.

II. MATERIAIS E MÉTODOS

GEOBIA

A Análise de Imagens Baseada em Objetos Geográficos (*Geographic Object-Based Image Analysis* - GEOBIA) pode ser considerada um método semiautomático de classificação de imagens de Sensoriamento Remoto (BLASCHKE, 2010; HAY; CASTILLA, 2008). Diversas pesquisas têm demonstrado que a GEOBIA produz resultados mais acurados na classificação de uso e cobertura da terra quando comparadas às classificações *pixel-a-pixel* (MYINT et al., 2011; PLATT; RAPOZA, 2008; WHITESIDE; AHMAD, 2005; CIVCO et al., 2002).

A GEOBIA é composta por dois procedimentos sequenciais: segmentação e classificação. A segmentação é o processo de dividir a imagem em agrupamentos de *pixels* homogêneos (BENZ et al., 2004; BAATZ; SCHÄPE, 2000). A qualidade e acurácia dos resultados dependem significativamente deste procedimento (BAATZ; SCHÄPE, 2000). Apesar de existirem abordagens quantitativas para definição dos parâmetros ótimos de segmentação (JOHNSON et al., 2015; ZHANG et al., 2015; DRĂGUȚ et al., 2014; HAPP; FEITOSA; STREET, 2012), a grande maioria das pesquisas ainda se baseia em procedimentos de tentativa e erro (HAY; CASTILLA, 2008).

Os objetos gerados na segmentação são classificados a partir de seus atributos. Suas características espaciais ou hierárquicas são expressas pela quantificação das informações multiespectrais, geométricas, texturais ou relacionais (BLASCHKE, 2010; BENZ et al., 2004).

Os dois procedimentos de atribuição de classes aos objetos são: baseada em regras (*Rule-Based*), e vizinho mais próximo (*Nearest Neighbour*) (MYINT et al., 2011). Como o vizinho mais próximo depende de uma fase de treinamento e amostragem, torna-se intransferível para outras áreas de estudo (HODGSON et al., 2003). De forma análoga, os métodos de mineração de dados (*Data Mining*), utilizados para automatizar a seleção de atributos ótimos para classificações baseadas em regras, tampouco são transferíveis (BELGIU; DRĂGUȚ; STROBL, 2014).

A classificação baseada em regras é construída com base no conhecimento prévio e *expertise* dos analistas. Assim, apresenta elevado potencial de transferência para outras áreas de estudo (ANDERS; SEIJMONSBERGEN; BOUTEN, 2015; HAMEDIANFAR; SHAFRI, 2015; BELGIU; DRĂGUȚ; STROBL, 2014; NOVACK et al., 2014; KOHLI et al., 2013).

Ainda que essa transferência seja factível, raras exceções, como a pesquisa Belgiu; Drăguț; Strobl (2014), analisaram a variabilidade das regras de classificação produzidas por diferentes analistas e a acurácia dos respectivos resultados. Além disso, diversos trabalhos indicam que distintos analistas selecionam diferentes atributos para classificação dos mesmos objetos-alvos (ARDELEAN et al., 2013; ALBRECHT; LANG; HÖLBLING, 2010; ZHOU; SCHWARZ; CADENASSO, 2010).

Área de estudo

A pesquisa foi realizada no município de Marília - SP (Figura 1). As duas cenas utilizadas foram extraídas da mesma imagem de satélite, e representam parte da área urbana do município. A cena #1 está localizada na zona leste cidade e possui uma extensão de 5081 x 3939 *pixels*. Compreende uma variabilidade significativa de habitações urbanas (de condomínios de alto padrão a assentamentos informais), extensas áreas de vegetação (arbórea e herbácea), além de possuir rios e lagos urbanos. A cena #2 está localizada na zona centro-sul da cidade. Possui dimensões similares (5477 x 3408) e elementos análogos aos da cena #1.

Ambas as cenas foram extraídas da imagem do satélite WorldView-II, de 18/08/2010, georreferenciada e ortorretificada com 2 metros de resolução espacial nas bandas multiespectrais e 50 centímetros na banda pancromática, com resolução espectral composta por três bandas do visível – RGB e uma do infravermelho próximo – NIR.

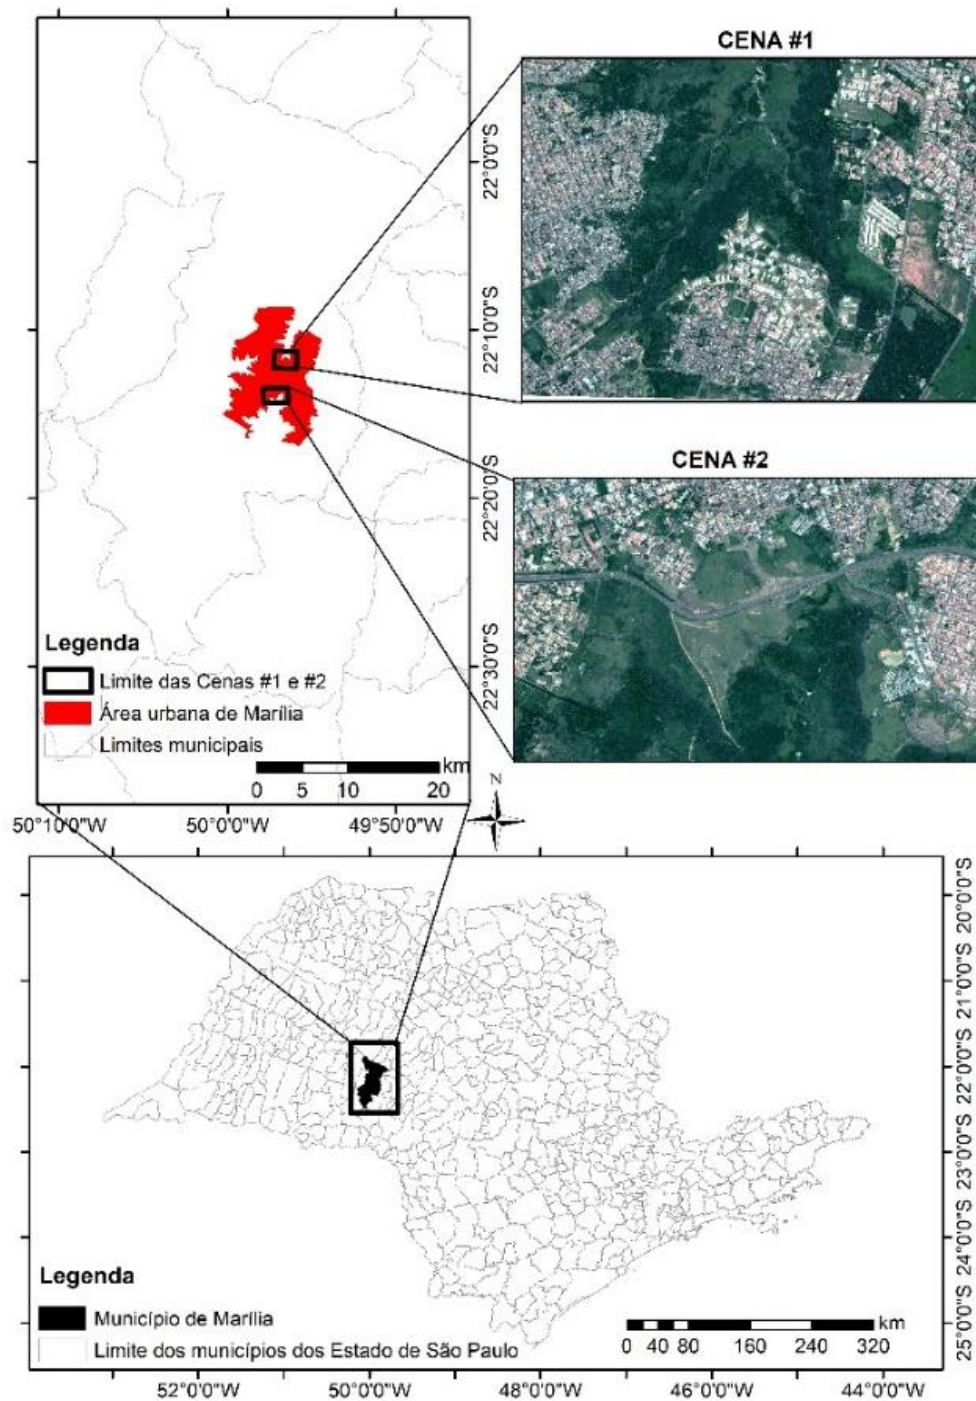


Figura 1 - Área de estudo: cenas #1 e #2. (elaborado pelos autores)

Procedimentos

A pesquisa foi realizada em três etapas principais. Na primeira, as regras de classificação foram criadas por quatro analistas (A1, A2, A3 e A4) no programa eCognition e aplicadas à cena #1. Na segunda, as mesmas

as regras da cena #1 foram reproduzidas na cena #2 de forma autônoma pelos mesmos analistas. Na terceira, o potencial de transferência das regras de classificação foi analisado, de formas qualitativa e quantitativa.

As classificações da cobertura da terra foram realizadas por quatro analistas distintos, que trabalharam separadamente. Nenhum deles tinha experiência em classificação de imagens do satélite WorldView-II e tampouco dos procedimentos de GEOBIA. A chave de interpretação (Figura 2) foi definida previamente e uma descrição detalhada das seis classes foi fornecida para reduzir a variabilidade na conceituação semântica dos objetos geográficos.







Classes	WorldView II image (RGB)	Contexto, forma e textura	Classes	WorldView II image (RGB)	Contexto, forma e textura
Vegetação arbórea		Localizado nos arredores do ambiente construído, com alguns elementos contidos entre blocos. Tem textura áspera, com variação no tamanho dos elementos.	Lagos		Eles estão localizados longe do espaço intra-urbano, perto de áreas de árvores e grama. Tem uma forma arredondada e textura lisa.
Vegetação herbácea		Localizado nos arredores do ambiente construído, com alguns elementos contidos entre blocos. Tem textura lisa com tendência a homogeneidade.	Solo exposto		Localizado dentro de blocos em novas subdivisões de lotes, terrenos não utilizados ou em ruas não pavimentadas. Tem formas, tamanhos e texturas variáveis.
Rios		Eles estão localizados longe do espaço intra-urbano, perto de áreas de árvores e grama. Tem uma forma alongada e textura lisa.	Áreas construídas		Tende a ocorrer de forma concentrada e regular, em diversas formas e tamanhos. Composta de uma variedade significativa de materiais. Possui textura rugosa.

Figura 2 - Chave de interpretação das classes de cobertura da terra. (elaborado pelos autores)

O primeiro procedimento, comum a todos os analistas, foi determinar os valores dos três parâmetros de segmentação da imagem: escala (*scale*), compactidade (*compactness*) e forma (*shape*). O parâmetro de escala refere-se ao grau de tolerância à heterogeneidade dos *pixels* para seu agrupamento em um único segmento e determina o tamanho dos objetos (BAATZ; SCHÄPE, 2000). De forma geral, quando maior a escala, maior os objetos. O parâmetro de compactidade está relacionado aos aspectos geométricos dos objetos e à suavidade das bordas. Ambos são complementares, ou seja, quanto maior a compactidade, menor a suavidade (BAATZ; SCHÄPE, 2000). É comum adotar valores mais altos de suavidade quando os alvos são feições naturais. A forma, por sua vez, é complementar à cor (BAATZ; SCHÄPE, 2000). Quando maior o valor atribuído, maior relevância dos aspectos espectrais em detrimento da geometria dos objetos.

Avaliação e comparação dos resultados

Os resultados das classificações foram avaliados a partir da matriz de confusão, para quantificar os erros de omissão e comissão de cada classe, e coeficiente *kappa* (CONGALTON, 1991). Apesar das limitações do *kappa* terem sido, amplamente, discutidas pela literatura (FOODY, 2020; KERR; FISCHER; REULKE, 2015; PONTIUS JR; MILLONES, 2011), não existe uma concordância entre os pesquisadores sobre possíveis substitutos. Além disso, uma gama de pesquisas ainda utiliza o *kappa* para quantificar acurácia de mapeamentos temáticos por GEOBIA (MAXWELL et al., 2019; PRADO; RUIZ, 2019; COLARES et al., 2015; BELGIU; DRĂGUȚ; STROBL, 2014; FRANCISCO; ALMEIDA, 2012; KIM et al., 2011).

Para o cálculo da matriz de confusão e coeficiente *kappa* foram utilizados 360 pontos aleatórios, estratificados entre as seis classes de cobertura (60 pontos por classe), como sugerem Herold et al., (2008) e Scepan (1999), para cada uma das cenas. A interpretação dos índices seguiu a proposta de Landis e Koch (1977), representada na Quadro 1.

Quadro 1 - Interpretação dos valores do índice *kappa*.

Valores de <i>kappa</i>	Interpretação
< 0	Sem concordância
0 – 0,19	Pouca concordância
0,2 – 0,39	Concordância razoável
0,4 – 0,59	Concordância média
0,6 – 0,79	Concordância considerável
0,8 – 1,0	Concordância excelente

Fonte: Landis e Koch (1977 p. 165).

A variabilidade entre as regras de classificação foi computada através do teste de McNemar (FOODY, 2004). O teste de McNemar é um teste não paramétrico utilizado para comparar algoritmos de classificação de imagens de sensoriamento remoto (DURO; FRANKLIN; DUBÉ, 2012; DE LEEUW et al., 2006). De acordo com Foody (2004), o teste é formalmente computado através da equação:

$$Z = \frac{f_{12} - f_{21}}{\sqrt{f_{12} + f_{21}}} \quad (1)$$

Onde f_{12} indica o número de amostras classificadas corretamente na primeira classificação, mas incorretamente na segunda e f_{21} representa o número de amostras classificadas corretamente na segunda classificação e incorretamente na primeira (FOODY, 2004). Sua interpretação é simples: quanto mais elevado o

valor de z , maior a variabilidade de acertos e erros, conseqüentemente, menor a capacidade de transferência das regras.

III. RESULTADOS

Estratégias e parâmetros de classificação

Os quatro analistas adotaram uma estratégia de classificação hierárquica, abordagem *top-down*, e utilizaram o algoritmo MRS (*Multiresolution Segmentation*) (BAATZ; SCHÄPE, 2000) para segmentar a imagem.

Os parâmetros segmentação adotados apresentaram similaridade. O *scale* apresentou maior variabilidade, entre 150 e 300 ($A1 = 250$, $A2 = 300$, $A3 = 150$ e $A4 = 150$), o parâmetro *compactness* variou entre 0,4 e 0,6 ($A1 = 0,6$, $A2 = 0,4$, $A3 = 0,4$ e $A4 = 0,5$), e o *shape* não variou entre os analistas (0,1).

As árvores de decisão apresentaram divergências significativas em relação à seleção dos atributos quantificáveis e ao ordenamento hierárquico utilizado (Figuras 3a e 3b). Os atributos quantificáveis utilizados nas quatro classificações estão sintetizados no Quadro 2.

O procedimento comum foi o iniciar o processo de classificação separando as classes de vegetação (arbórea e herbácea) das demais classes. Os quatro analistas utilizaram o índice NDVI (*Normalized Difference Vegetation Index*) cujo limiar variou entre 0,31 e 0,44. Posteriormente, as classes de vegetação foram separadas utilizando diferentes regras e, na seqüência, foram classificadas as outras classes de cobertura.

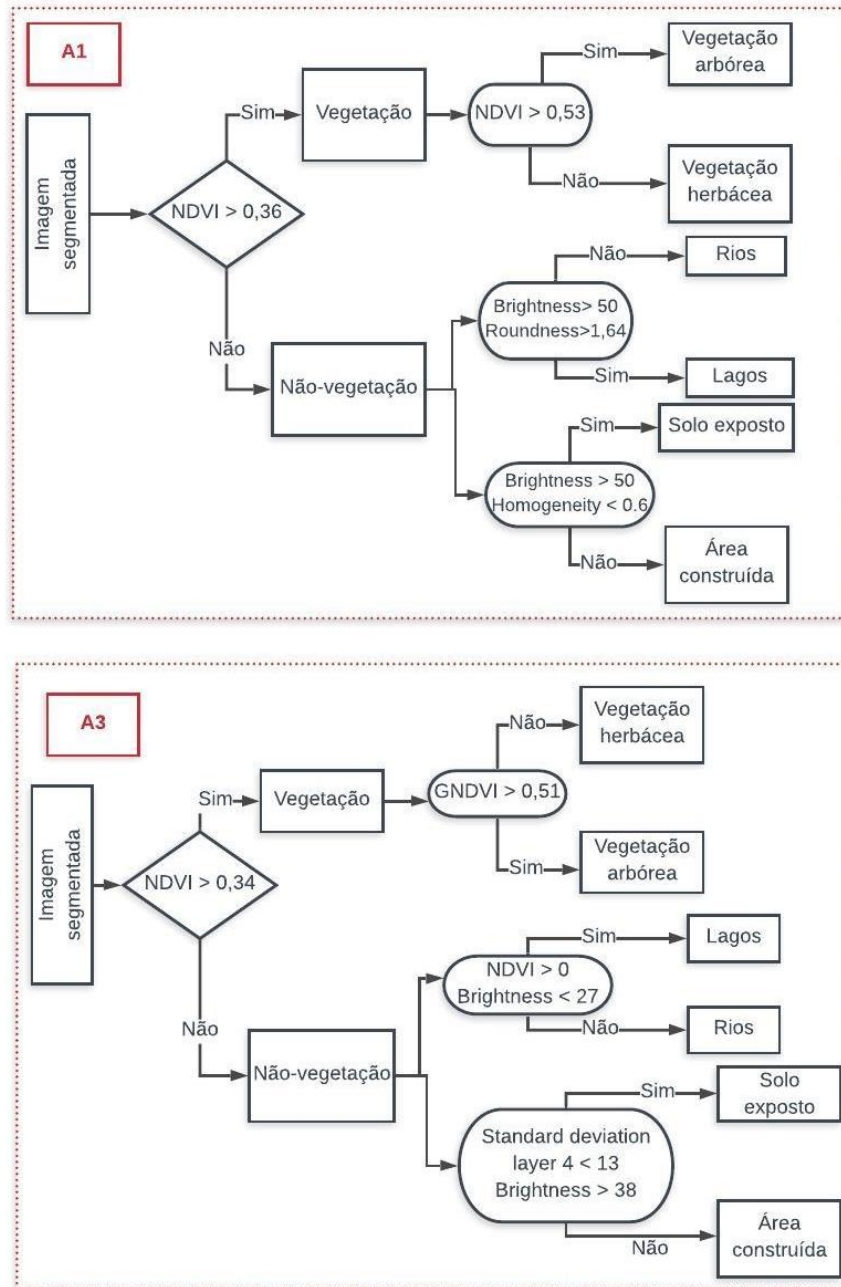


Figura 3a - Árvore de decisão dos analistas A1 e A3. (elaborado pelos autores)

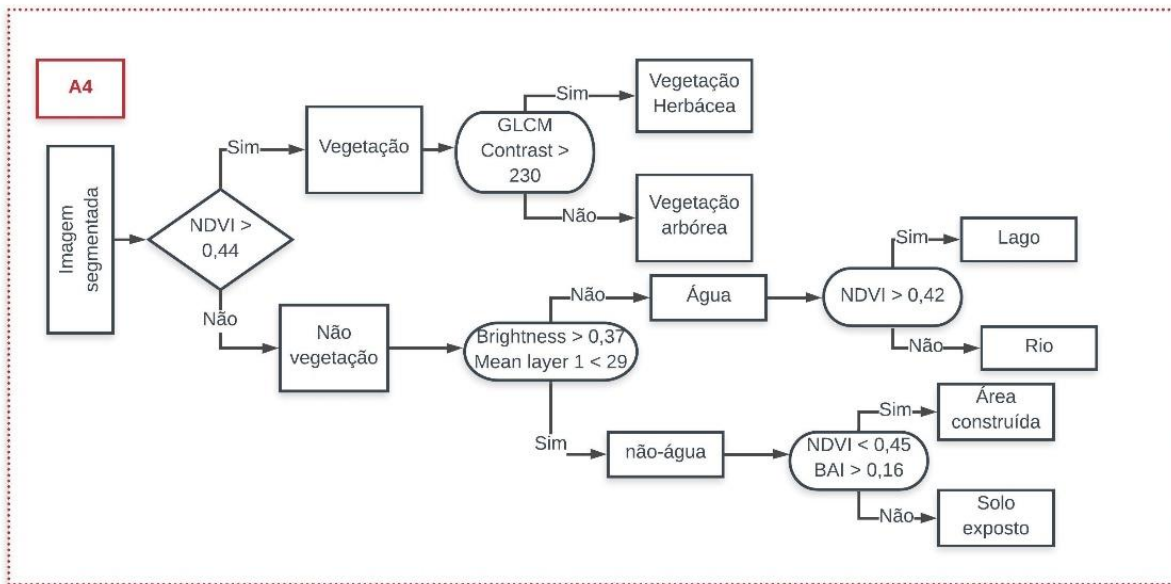
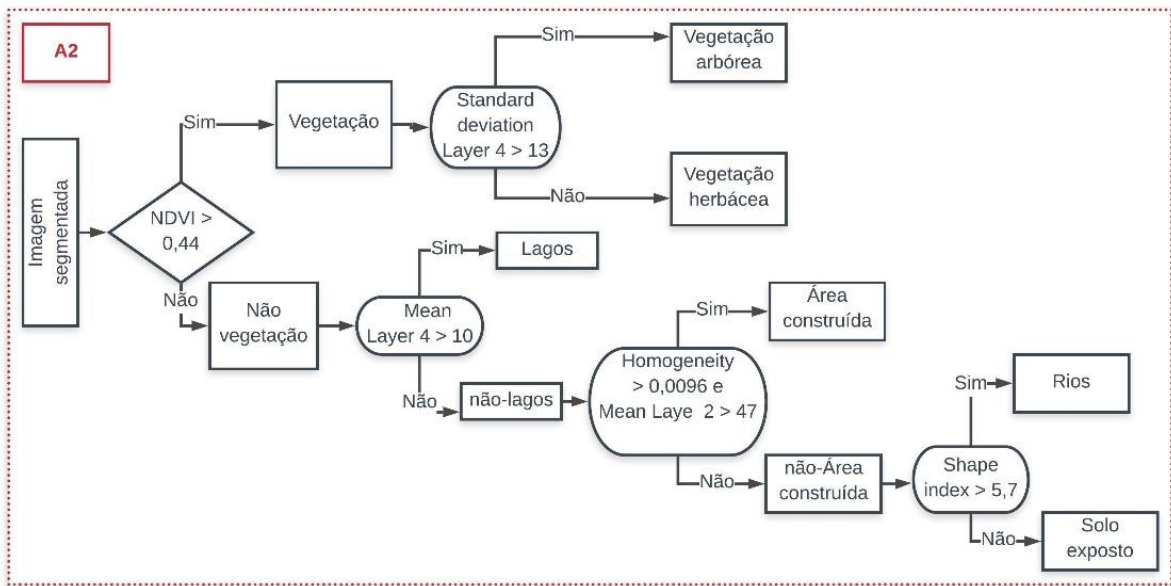


Figura 3b - Árvore de decisão dos analistas A2 e A4. (elaborado pelos autores)

Quadro 2 - Atributos quantificáveis e variáveis do eCognition.

Tipo de atributo	Nome do atributo quantificável	Formulação matemática	Descrição
Espectral	NDVI	$NDVI = mean \left(\frac{NIR-RED}{NIR+RED} \right)$	O NDVI varia entre: -1,0 e +1,0; RED = banda do vermelho NIR = banda do infravermelho próximo
	GNDVI	$GNDVI = mean \left(\frac{NIR-GREEN}{NIR+GREEN} \right)$	O GNDVI é uma versão do NDVI calculado com a banda do verde. Os valores variam entre -1,0 e +1,0.
	Brightness	$B = \frac{1}{n_{vis}} \sum_{i=1}^{n_{vis}} C_i(vis)$	B é a média do brilho de um objeto e $C_i(vis)$ é a soma dos valores de brilho das bandas do visível dividido pelo número de bandas do visível n_{vis} .
	Standard deviation layer 4 (NIR)	Banda 4 = desvio padrão (NIR)	O desvio padrão da banda 4 é o valor do desvio padrão de um objeto na banda 4 (NIR)
	Mean layer 1 (BLUE)	Banda 1 = media (BLUE)	A média da banda 1 é o valor médio de um objeto na banda 1 (BLUE)
	Mean layer 4 (NIR)	Banda 4 = media (NIR)	A média da banda 4 é o valor médio de um objeto na banda 4 (NIR)
	BAI (Built-up Areas Index)	$BAI = mean \left(\frac{BLUE-NIR}{BLUE+NIR} \right)$	O BAI varia entre: -1,0 e +1,0 BLUE = banda do azul NIR = banda do infravermelho próximo
Geométrico	Roundness	$\mu_C(x) = \left\{ 1 - \frac{1-x}{1-C} \right\}$ for $0 \leq x - C \geq 1 - C$	Descreve quanto (x) um objeto geográfico cabe dentro de um círculo (C); apresenta valores entre 1 (encaixe perfeito) e 0 (não encaixa).
	Shape Index	$SI = 1,27 AL^2$	Indica a forma dos objetos, de circular à retangular. A= representa a área do objeto em km ² e L = comprimento do eixo mais longo em km. O valor de 1,0 expressa a forma circular que recebe valores menores quando é alongada.
Textural	GLCM Homogeneity	$H = \sum_{i,j=0}^{N_g-1} \frac{1}{1+(i-j)} g(j, j)$	É uma medida de sensibilidade à presença de elementos quase diagonais em um GLCM (matriz de coocorrência de nível de cinza) N_g é o número de níveis de cinza e $g(j, j)$ é a entrada i, j no GLCM
	GLCM Contrast	$C = \sum_{i,j=0}^{N_g-1} P_{ij} (i - j)^2$	É uma medida da diferença entre a medida de intensidade de contraste do pixel em questão e do seu vizinho e os valores de contraste da matriz de coocorrência de níveis de cinza (GLCM). P_{ij} é o elemento i, j do GLCM e N_g é o número de níveis de cinza.

Adaptado de Araujo e Queiroz (2018)

Avaliação das classificações (cena #1)

Os resultados das classificações da cena #1 estão apresentados na Figura 4. Todos os analistas produziram classificações consideradas muito boas de acordo com Landis e Koch (1977). O analista A2 obteve maior *kappa* (0,87) demonstrando ter aplicado o conjunto de regras com maior eficiência.

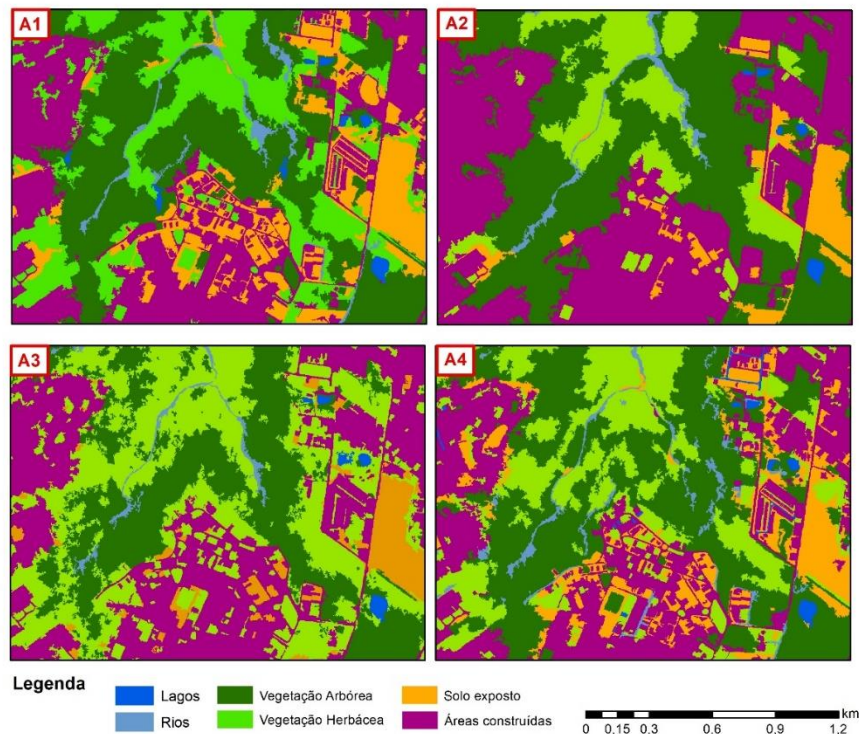


Figura 4 - Resultados da classificação da cena #1. (elaborado pelos autores)

A classe “lagos” foi a de maior acerto entre os analistas (Tabela 1 e Figura 5). O analista A2, no entanto, apresentou precisão da classificação dos lagos um pouco abaixo do restante (acerto de 90%). Ao adotar valor mais elevado no parâmetro *scale* (300), durante a segmentação, houve maior confusão com a vegetação arbórea do entorno dos lagos. A classe “áreas construídas” também apresentou excelentes resultados, com porcentagem de acerto acima de 93% para todos os analistas.

Tabela 1 - Matriz de confusão e índice kappa da classificação de cobertura da cena #1.

A1								A2							
	R	L	VA	VH	SE	AC	TOTAL		R	L	VA	VH	SE	AC	TOTAL
R	49	0	1	0	1	0	51	R	52	0	0	0	3	0	55
L	1	60	0	0	0	0	61	L	0	54	0	0	0	0	54
VA	3	0	51	11	0	0	65	VA	4	6	60	8	2	0	80
VH	6	0	8	47	4	0	65	VH	4	0	0	50	0	0	54
SE	1	0	0	2	43	4	50	SE	0	0	0	2	44	0	46
AC	0	0	0	0	12	56	68	AC	0	0	0	0	11	60	71
TOTAL	60	60	60	60	60	60	360	TOTAL	60	60	60	60	60	60	360
<i>kappa</i> = 0,82								<i>kappa</i> = 0,87							
A3								A4							
	R	L	VA	VH	SE	AC	TOTAL		R	L	VA	VH	SE	AC	TOTAL
R	45	0	0	0	0	0	45	R	44	0	0	0	0	0	44
L	0	60	0	0	0	0	60	L	0	60	0	0	0	0	60
VA	3	0	53	3	0	0	59	VA	10	0	52	13	2	0	77
VH	12	0	7	57	18	2	96	VH	5	0	8	45	4	1	63
SE	0	0	0	0	30	0	30	SE	0	0	0	2	35	1	38
AC	0	0	0	0	12	58	70	AC	1	0	0	0	19	58	78
TOTAL	60	60	60	60	60	60	360	TOTAL	60	60	60	60	60	60	360
<i>kappa</i> = 0,81								<i>kappa</i> = 0,78							

Legenda: R: rio, L: lago, VH: vegetação herbácea, VA: vegetação arbórea, SE: solo exposto; AC: áreas construídas.

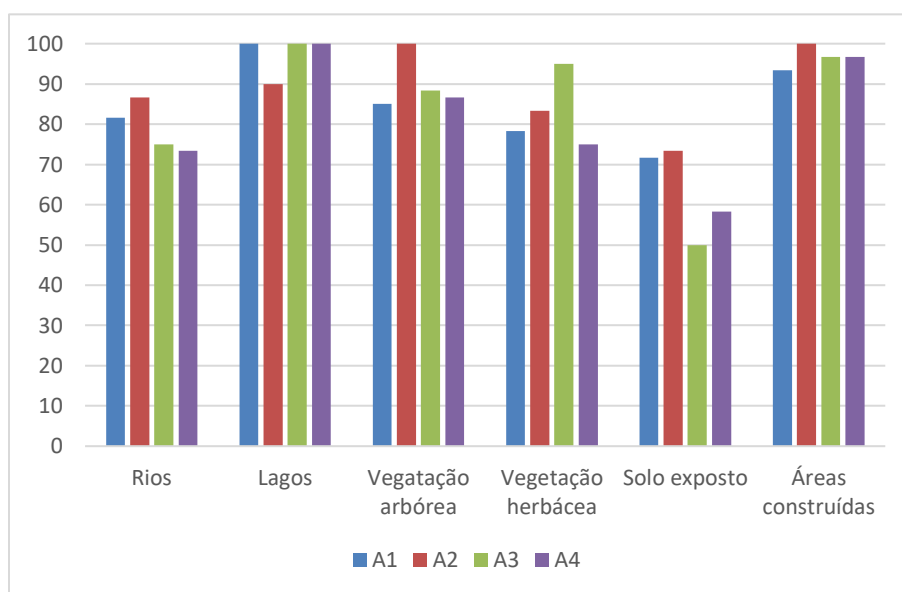


Figura 5 - Porcentagem de acerto da classificação da cena #1 por analista. (elaborado pelos autores)

A classe “solo exposto” apresentou maior grau de confusão e menor porcentagem de acerto de classificação entre todos os analistas, mesmo utilizando o BAI (*Built-up Areas Index*), aplicado pelo analista A4.

Recorrente, a confusão entre as classes “solo exposto” e “áreas construídas” ocorreu devido à similaridade das assinaturas espectrais. O analista A3 apresentou menor porcentagem de acerto desta classe (50%). A classe de “vegetação arbórea” apresentou porcentagem de acerto satisfatória, acima de 80% para todos os analistas, e confusão mais elevada com classe de “vegetação herbácea”.

As classes “rios” e “vegetação herbácea” apresentaram porcentagem de acerto mediana na maioria dos analistas (entre 70% e 86,6%). E nível de confusão mais relevante com a classe de “vegetação arbórea”. O analista A4 apresentou menor porcentagem de acerto para ambas as classes (73,3% e 75%).

Avaliação das classificações da cena #2

O conjunto de regras de classificação da cena #1 foi aplicado na cena #2 (Figura 6). O tamanho da cena #2 é similar ao da cena #1, de forma que as variações de tamanho dos objetos gerados no processo de segmentação fossem pouco significativas.

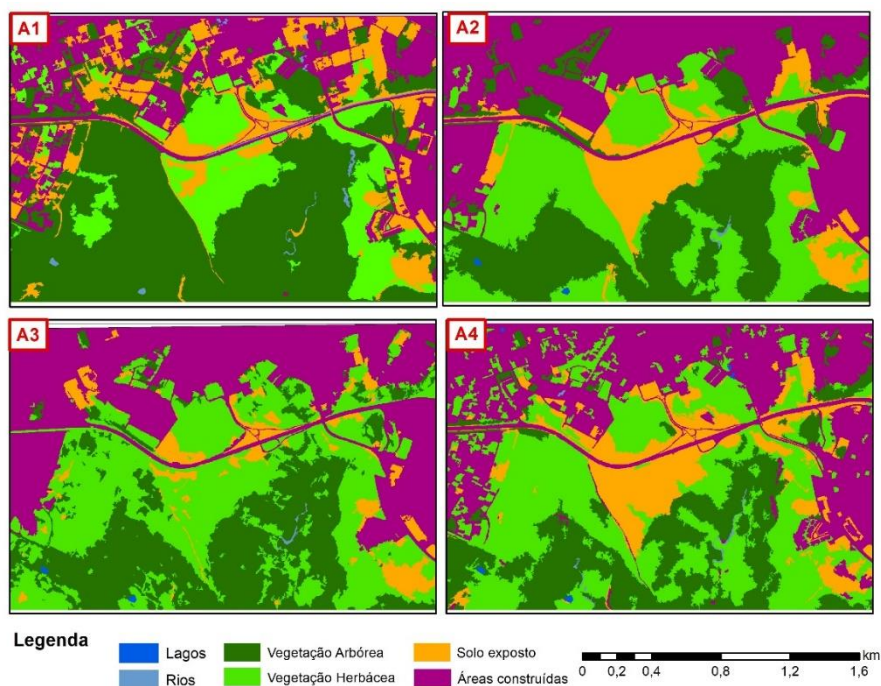


Figura 6 - Resultados da classificação da cena #2. (elaborado pelos autores)

A interpretação visual dos resultados aponta que a classe “rios” obteve mais erros de omissão e comissão. A maior confusão se deu em relação à classe de “vegetação arbórea”, especialmente para o conjunto de regras dos analistas A1 e A2 (Tabela 2 e Figura 7). Acredita-se que o uso de regras como o GNDVI e o parâmetro de textura GLCM Contraste, adotados pelos analistas A3 e A4, respectivamente, tenha melhorado a acurácia da classificação da classe “vegetação arbórea” e reduzido a confusão.

A exemplo da cena #1, a classe “lagos” foi que a obteve maior acerto entre todos os analistas da cena #2 (acima de 90%). Os melhores resultados dos analistas A3 e A4 indicaram que a adoção de parâmetros de geometria não representa melhoria da eficiência da classificação. Ambos utilizaram parâmetros espectrais e alcançaram maior precisão nesta classe.

Tabela 2 - Matriz de confusão e índice kappa da classificação de cobertura da cena #2.

A1								A2							
	R	L	VA	VH	SE	AC	TOTAL		R	L	VA	VH	SE	AC	TOTAL
R	9	0	0	0	0	0	9	R	14	0	0	0	0	0	14
L	0	56	0	0	0	0	56	L	0	57	0	0	0	0	57
VA	45	4	60	33	2	3	147	VA	36	0	58	5	1	0	100
VH	0	0	0	26	4	2	32	VH	10	3	2	49	5	0	69
SE	6	0	0	1	52	15	74	SE	0	0	0	6	48	0	54
AC	0	0	0	0	2	40	42	AC	0	0	0	0	6	60	66
TOTAL	60	60	60	60	60	60	360	TOTAL	60	60	60	60	60	60	360
<i>kappa</i> = 0,60								<i>kappa</i> = 0,75							
A3								A4							
	R	L	VA	VH	SE	AC	TOTAL		R	L	VA	VH	SE	AC	TOTAL
R	40	0	0	0	0	0	40	R	49	0	0	0	0	0	49
L	0	60	0	0	0	0	60	L	0	60	0	0	0	0	60
VA	6	0	60	9	0	0	75	VA	22	0	51	5	0	0	78
VH	14	0	0	51	18	0	83	VH	13	0	9	48	0	5	75
SE	0	0	0	0	36	1	37	SE	0	0	0	7	44	0	51
AC	0	0	0	0	6	59	65	AC	1	0	0	0	16	55	72
TOTAL	60	60	60	60	60	60	360	TOTAL	60	60	60	60	60	60	360
<i>kappa</i> = 0,82								<i>kappa</i> = 0,76							

Legenda: R: rio, L: lago, VH: vegetação herbácea, VA: vegetação arbórea, SE: solo exposto; AC: áreas construídas.

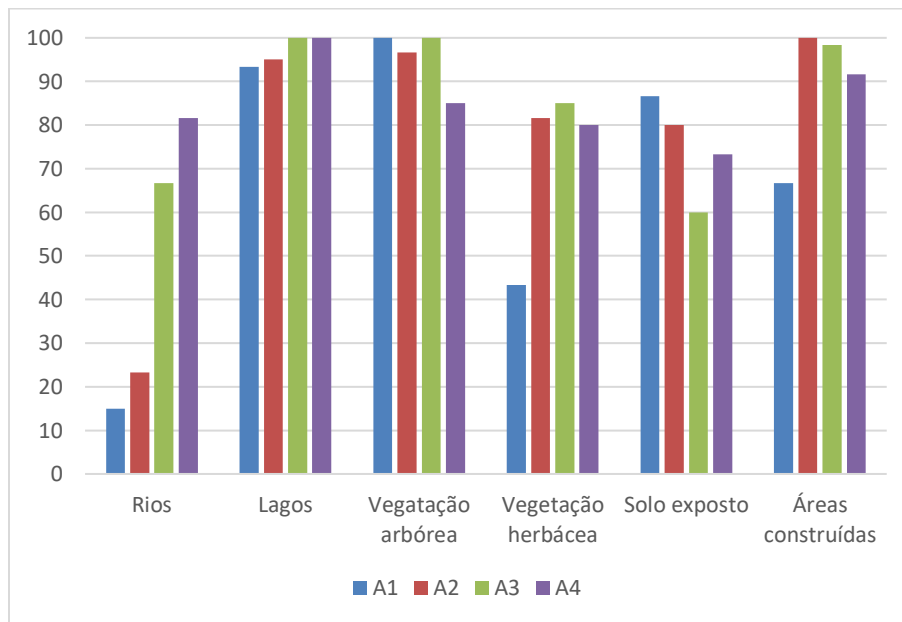


Figura 7 - Porcentagem de acerto da classificação da cena #2 por analista. (elaborado pelos autores)

Foi significativo o nível de acerto dos analistas na classe “vegetação arbórea” (acima de 80%). Tal como na cena #1, a confusão mais elevada ocorreu em relação à classe “vegetação herbácea”, devida à similaridade espectral entre das classes de vegetação. Três analistas obtiveram elevada precisão na classe “áreas construídas” (acima de 90% de acerto). O desempenho do analista A1 (67% de acerto) foi considerado uma exceção. A combinação entre os parâmetros GLCM *Homogeneity* e *Brightness*, por ele utilizada, foi insuficiente para separar as classes que apresentaram maior confusão: “áreas construídas” e “solo exposto”.

Potencial de transferência

O potencial de transferência das regras de classificação foi testado com o teste de McNemar (Tabela 3), que comparou os resultados das classificações das cenas #1 e #2.

Tabela 3 - Teste de McNemar.

Analistas	<i>kappa</i> cena #1	<i>kappa</i> cena #2	Teste de McNemar
A1	0,82	0,60	6,89
A2	0,87	0,75	4,62
A3	0,81	0,82	- 0,5
A4	0,78	0,76	2,84

Os resultados mostraram que os analistas A2 e A4 obtiveram resultados semelhantes, com *kappa* 0,75 e 0,76, respectivamente, na cena #2. No entanto, o potencial de transferência do conjunto de regras do analista A4 foi maior de acordo com os resultados do teste de McNemar. O analista A1 não obteve bom desempenho na segunda área teste (*kappa*: 0,60 e Teste de McNemar: 6,89), o que indica baixo potencial de transferência e acurácia das regras de classificação.

O analista A3 atingiu um *kappa* ligeiramente mais elevado na cena #2 (0,01), em relação à cena #1, o que resultou em um valor negativo para o teste de McNemar. Estes resultados apontam que as regras de classificação do analista A3, além de possuírem alto potencial de transferência, atingiram valores de *kappa* considerados excelentes, conforme Landis e Koch (1977).

IV. DISCUSSÃO

Neste experimento, constatou-se que distintos analistas selecionaram diferentes atributos para classificação dos mesmos objetos-alvos. Esse resultado está de acordo com as observações de Ardelean et al. (2013), Albrecht; Lang; Hölbling (2010) e Zhou; Schwarz; Cadenasso (2010). A acurácia das classificações variou em função da escolha dos atributos quantificáveis utilizados na construção das regras de classificação, nos limiares estabelecidos, bem como dos níveis hierárquicos definidos.

Os analistas A2, A3 e A4 obtiveram bons resultados na exatidão e no potencial de transferência das regras de classificação. De certa forma, estes dados corroboram as afirmações de Belgiu, Drăguț e Strobl (2014) e Kohli et al., (2013) sobre a manutenção da consistência das regras de classificação em GEOBIA. Essa possibilidade de transferência indica que as bibliotecas de regras de classificação por objetos geográficos podem contribuir para otimizar o processo de classificação de imagens, reduzindo o número de horas de trabalho dos

analistas. Além disso, ratificam as vantagens de reprodução e compartilhamento, mencionadas por Haggett; Chorley (1974), sobre os modelos no contexto da Geografia.

Entretanto, é fundamental observar a necessidade de cautela no processo de segmentação da imagem, dada sua influência no resultado (BAATZ; SCHÄPE, 2000). Os resultados mostraram que a capacidade de transferência das regras foi atingida pela adoção dos mesmos parâmetros de segmentação e pela similaridade dos tamanhos das áreas de estudo (cenas #1 e #2). A variação nos parâmetros de segmentação pode afetar o tamanho dos objetos e, como consequência, reduzir a concordância entre as classificações (BELGIU; DRĂGUȚ; STROBL, 2014).

Além disso, a adoção do mesmo atributo quantificável (como o NDVI neste experimento), não seria suficiente para garantir resultados semelhantes na classificação, principalmente quando se adotam limiares diferentes. Esta observação é compatível com a abordagem de Pinho et al., (2012), que discutiram a dificuldade de adoção de um limiar adequado de NDVI para classificações de vegetação e de solo exposto.

A utilização do GNDVI para a separação de tipos de vegetação demonstrou ser adequada (ROUSE et al., 1973) e possuir significativo potencial de transferência. Da mesma forma, foi possível avaliar que o BAI e a classe de áreas construídas (*Built-up Areas Index*) também apresentaram considerável capacidade de transferência (ZHA; GAO; NI, 2003). O uso de atributos quantificáveis geométricos e texturais, no entanto, não apresentou influência positiva e constante no resultado da classificação. Esses atributos nem sempre mostraram potencial elevado de transferência ou contribuíram para aumentar o nível de acerto da classificação.

V. CONSIDERAÇÕES FINAIS

Este artigo analisou a variabilidade nas regras de classificação por GEOBIA, desenvolvidas por quatro analistas diferentes, que utilizaram a mesma chave de interpretação. O experimento foi realizado com uma imagem WorldView-II de Marília - SP. A acurácia, potencial de transferência e variabilidade das regras de classificação foi obtida através do coeficiente *kappa* e teste de McNemar.

Os quatro analistas produziram conjuntos distintos de regras e utilizaram: 1) atributos quantificáveis, 2) limiares e 3) níveis hierárquicos diferentes para classificação das classes de cobertura da terra. Essas diferenças afetaram a acurácia dos resultados. A capacidade de transferência das regras foi testada utilizando uma segunda área de estudo (cena #2), da mesma imagem de satélite. A avaliação demonstrou que o conjunto de regras dos analistas A2, A3 e A4 se mostrou consistente na cena 2 (*Kappas* de 0,75, 0,82 e 0,76) e transferível (McNemar: 4,62, -0,5 e 2,84).

Acredita-se que esses resultados ratificam o potencial da classificação de imagens por objetos geográficos, mencionados por Myint et al., (2011) e Platt e Rapoza, (2008), pois a GEOBIA se consolidou como um método que possibilita maior acurácia nas classificações de uso e cobertura da terra em comparação com as classificações *pixel-a-pixel*.

A pesquisa também mostrou que, mesmo sem nenhum conhecimento prévio sobre GEOBIA ou classificação de imagens de satélite, os analistas foram capazes de desenvolver classificações de cobertura da terra consideradas muito boas, conforme Landis e Koch (1977). Assim, a expectativa é de que os analistas mais experientes possam desenvolver regras de classificações com um nível ainda maior de acurácia e transferência.

Agradecimentos

Esta pesquisa teve o apoio financeiro do Conselho Nacional de Pesquisa (CNPq), processos 408077/2016-6 e 307725/2020-0.

VI. REFERÊNCIAS

- ALBRECHT, F.; LANG, S.; HÖBLING, D. Spatial accuracy assessment of object boundaries for object-based image analysis. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. 37, n. 1, p. 1–6, 2010.
- ANDERS, N. S.; SEIJMONSBERGEN, A. C.; BOUTEN, W. Rule set transferability for object-based feature extraction: an example for cirque mapping. *Photogrammetric Engineering & Remote Sensing*, v. 81, n. 6, p. 507–514, 2015.
- ARAÚJO, A. S.; QUEIROZ, A. P. Spatial Characterization and Mapping of Gated Communities. *International Journal of Geo-Information*, v. 7, n. 7, 2018.
- ARDELEAN, F.; DRĂGUȚ, L.; URDEA, P.; TÖRÖK-OANCE, M. Variations in landform definition: a quantitative assessment of differences between five maps of glacial cirques in the Țarcu Mountains. *Area*, v. 45, n. 3, p. 348–357, 2013.
- BAATZ, M.; SCHÄPE, A. Multi resolution Segmentation: an optimum approach for high quality multi scale image segmentation. In: STROBL, J.; BLASCHKE, T.; GRIESEBNER, G. (Eds.). *Angewandte Geographische Informations-Verarbeitung XII*. Karlsruhe: Wichmann Verlag, 2000. p. 12–23.
- BELGIU, M.; DRĂGUȚ, L.; STROBL, J. Quantitative evaluation of variations in rule-based classifications of land cover in urban neighborhoods using WorldView-2 imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 87, n. 1, p. 205–215, 2014.
- BENZ, U. C.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I.; HEYNEN, M. Multiresolution, object-oriented fuzzy analysis of remote sensing data for GIS ready information. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 65, n. 1, p. 2–16, 2004.
- BLASCHKE, T. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 65, n. 1, p. 2–16, 2010.

- CHEN, G.; WENG, Q.; HAY, G. F.; HE, Y. Geographic object-based image analysis (GEOBIA): emerging trends and future opportunities. *GIScience & Remote Sensing*, v. 55, n. 2, p. 159–182, 2018.
- CIVCO, D. L.; HURD, J. D.; WILSON, E. H.; SONG, M.; ZHANG, Z. A comparison of land use and land cover change detection methods. *ASPRS-ACSM ANNUAL CONFERENCE*, Washington, DC. Anais...2002.
- COLARES, I. V. V.; OLIVEIRA NUNES, M. T.; SOUSA, G. M.; FERNANDES, M. C. Aplicação de GEOBIA para classificação da cobertura da terra no Parque Nacional do Itatiaia. *Revista Brasileira de Geomática*, v. 3, n. 1, p. 24–31, 2015.
- CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing and Environment*, v. 37, n. 1, p. 35–46, 1991.
- DE LEEUW, J.; JIA, H.; YANG, L.; LIU, X.; SCHMIDT, K.; SKIDMORE, A. K. Comparing accuracy assessments to infer superiority of image classification methods. *International Journal of Remote Sensing*, v. 27, n. 1, p. 223–232, 2006.
- DRĂGUȚ, L.; CSILLIK, O.; EISANK, C.; TIEDE, D. Automated parameterisation for multi-scale image segmentation on multiple layers. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 88, n. 1, p. 119–127, 2014.
- DURO, D. C.; FRANKLIN, S. E.; DUBÉ, M. G. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. *Remote Sensing and Environment*, v. 118, n. 1, p. 259–272, 2012.
- FOODY, G. M. Thematic map comparison: evaluating the statistical significance of differences in classification accuracy. *Photogrammetric Engineering & Remote Sensing*, v. 70, n. 5, p. 627–634, 2004.
- FOODY, G. M. Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. *Remote Sensing of Environment*, v. 239, n. 1, p. 11–31, 2020.
- FOTHERINGHAM A.S.; ROGERSON P. *The SAGE Handbook of Spatial Analysis*. SAGE Publications Ltd All, London. 2009.
- FRANCISCO, C. N.; ALMEIDA, C. M. Interpretação de imagens orbitais por meio de sistema especialista para o mapeamento de cobertura da terra em região montanhosa. *Sociedade e Natureza*, v. 24, n. 2, p. 283–301, 2012.
- GARDIN, S.; VAN LAERE, S. M.; VAN COLLIE, F. M. B.; ANSEEL, F.; DUYCK, W.; DE WULF, R. R.; VERBEKE, L. P. C. Remote sensing meets psychology: a concept for operator performance assessment. *Remote Sensing Letters*, v. 2, n. 3, p.251-257, 2011.
- HAGGETT, P.; CHORLEY, R.J. Modelos, paradigmas e a Nova Geografia. In: CHORLEY, R.J.; HAGGETT, P. *Rio de Janeiro: Livros Técnicos e Científicos Editora e EDUSP*, p. 1-22, 1974.
- HAMEDIANFAR, A.; SHAFRI, H. Z. M. Detailed intra-urban mapping through transferable OBIA rule sets using WorldView-2 very-high-resolution satellite images. *International Journal of Remote Sensing*, v. 36, n. 1, p. 3380–3396, 2015.
- HAPP, P. N.; FEITOSA, R. Q.; STREET, A. Assessment of optimization methods for automatic tuning of segmentation parameters. *Proceedings of the 4th GEOBIA*. Anais...Rio de Janeiro: 2012
- HARVEY, D. Modelos da evolução dos padrões espaciais na geografia. In: CHORLEY, R.J.; HAGGETT, P. *Rio de Janeiro: Livros Técnicos e Científicos Editora e EDUSP*, p. 101-155, 1974

- HAY, G. J.; CASTILLA, G. Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. In: BLASCHKE, T.; LANG, S.; HAY, G. J. (Eds.). Object-based image analysis. Berlin: Springer-Heidelberg, 2008. p. 75–89.
- HEROLD, M.; MAYAUX, P.; WOODCOCK, C. E.; BACCINI, A.; SCHMULLIUS, C. Some challenges in global land cover mapping: an assessment of agreement and accuracy in existing 1 km datasets. *Remote Sensing and Environment*, v. 112, n. 5, p. 2538–2556, 2008.
- HODGSON, M.; JENSEN, J. R.; TULLIS, J. A.; RIORDAN, K.; ARCHER, C. M. Synergistic use of lidar and color aerial photography for mapping urban parcel imperviousness. *Photogrammetric Engineering and Remote Sensing*, v. 69, n. 9, p. 973–980, 2003.
- JOHNSON, B. A.; BRAGAIS, M.; ENDO, I.; MAGCALE-MACANDOG, D. B.; MACANDOG, P. B. M. Image segmentation parameter optimization considering within-and between-segment heterogeneity at multiple scale levels: Test case for mapping residential areas using landsat imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 4, n. 4, p. 2292–2305, 2015.
- KERR, G. H. G.; FISCHER, C.; REULKE, R. Reliability assessment for remote sensing data: Beyond Cohen's kappa. *IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS)*. Anais...2015
- KIM, M. WARNER, T. A.; MADDEN, M.; ATKINSON, D. S. Multi-scale GEOBIA with very high spatial resolution digital aerial imagery: scale, texture and image objects. *International Journal of Remote Sensing*, v. 32, n. 10, p. 2825–2850, 2011.
- KOHLI, D.; WARWADEKAR, P.; KERLE, N.; SLIUZAS, R.; STEIN, A. Transferability of object-oriented image analysis methods for slum identification. *Remote Sensing*, v. 5, n. 9, p. 4209–4228, 2013.
- LANDIS, R. J.; KOCH, G. G. The Measurement of Observed Agreement for Categorical Data. *Biometrics*, v. 33, n. 1, p. 159–174, 1977.
- LIU, X.; HE, J.; YAO, Y.; ZHANG, J.; LIANG, H.; WANG, H.; HONG, Y. Classifying urban land use by integrating remote sensing and social media data. *International Journal Geographical Information Science*, v. 31, n. 8, p. 1675–1696, 2017.
- MAHDAVI, S.; SALEHI, B.; GRANGER, J.; AMANI, M.; BRISCO, B.; HUANG, W. Remote sensing for wetland classification: A comprehensive review. *GIScience & Remote Sensing*, v. 55, n. 5, p. 623–658, 2018.
- MAXWELL, A. E. et al. Large-Area, High Spatial Resolution Land Cover Mapping Using Random Forests, GEOBIA, and NAIP Orthophotography: Findings and Recommendations. *Remote Sensing*, v. 11, n. 12, p. 1409–1429, 2019.
- MYINT, S. W.; GOBER, P.; BRAZEL, A.; GROSSMAN-CLARKE, S.; WENG, Q. Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*, v. 115, n. 5, p. 1145–1161, 2011.
- NOVACK, T.; KUX, H.; FEITOSA, R. Q.; COSTA, G. A. A knowledge-based, transferable approach for block-based urban land-use classification. *International Journal of Remote Sensing*, v. 35, n. 13, p. 4739–4757, 2014.
- PINHO, C. M. D.; FONSECA, L. M. G.; KORTING, T. S.; ALMEIDA, C. M. Land-cover classification of an intra-urban environment using high-resolution images and object-based image analysis. *International Journal of Remote Sensing*, v. 33, n. 19, p. 5973–5995, 2012.
- PLATT, R. V.; RAPOZA, L. An evaluation of an object-oriented paradigm for land use/land cover classification. *The Professional Geographer*, v. 60, n. 1, p. 87–100, 2008.

- PONTIUS JR, 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, 2011.
- PRADO, D. P.; RUIZ, L. A. Comparative of Machine Learning Algorithms and Datasets to Classify Natural Coverage in the Cajas National Park (Ecuador) Based on GEOBIA Approach. *MULTIDISCIPLINARY DIGITAL PUBLISHING INSTITUTE PROCEEDINGS*. Anais...2019
- ROUSE JR, J. W. et al. Monitoring vegetation systems in the great plains with ERTS. Third ERTS symposium, NASA SP-351. Anais...Washington, D. C.: 1973
- SCEPAN, J. Thematic validation of high-resolution global land-cover data sets. *Photogrammetric Engineering and Remote Sensing*, v. 656, n. 1, p. 1051–1060, 1999.
- TANG, H.; WU, W.; YANG, P.; PENG, Y.; VERBURGET, P.H. Recent progresses of land use and land cover change (LUCC) models. *Acta Geographica Sinica – Chinese Edition*, 2009. v. 64, p. 456-468
- WHITESIDE, T.; AHMAD, W. A comparison of object-oriented and pixel-based classification methods for mapping land cover in northern Australia. *SPATIAL INTELLIGENCE, INNOVATION AND PRAXIS: The national biennial conference of the Spatial Sciences Institute*. Anais...2005
- ZHA, Y.; GAO, J.; NI, S. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, v. 24, n. 3, p. 583–594, 2003.
- ZHANG, X.; FENG, X.; XIAO, P.; HE, G.; ZHU, L. Segmentation quality evaluation using region based precision and recall measures for remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 102, n. 1, p. 73–84, 2015.
- ZHOU, W.; SCHWARZ, K.; CADENASSO, M. Mapping urban landscape heterogeneity: agreement between visual interpretation and digital classification approaches. *Landscape and Ecology*, v. 25, n. 1, p. 53–67, 2010.
-