CLASSIFICAÇÃO DA COBERTURA DO SOLO URBANO USANDO ÁRVORES DE DECISÃO A PARTIR DE UMA CENA WORLDVIEW-2 PARA DIFERENTES NÍVEIS DE LEGENDA

DECISION TREES-BASED URBAN LAND COVER CLASSIFICATION OF WORLDVIEW-2 SCENES AT DIFFERENT LEGEND LEVELS

Paulo Roberto da Silva RUIZ¹, Cláudia Maria de ALMEIDA¹, Camila Souza dos ANJOS²

¹Instituto Nacional de Pesquisas Espaciais – INPE. Divisão de Sensoriamento Remoto. São José dos Campos, Brasil Email: paulo.ruiz@inpe.br; almeida@dsr.inpe.br

²Instituto de Estudos Avançados – IEAv. Subdivisão de Sensoriamento Remoto. Força Aérea Brasileira. São José dos Campos, Brasil Email: camilasanjos@gmail.com

> Introdução Material e Métodos Área de Estudo Dados de Entrada Fluxograma Metodológico Classificação da Imagem WV-2 Algoritmos de Árvore de Decisão Avaliação dos Resultados Resultados para o Nível de Legenda 1 Resultados para o Nível de Legenda 2 Resultados para o Nível de Legenda 2 Resultados dos Índices Kappa Condicionais e Testes de Hipóteses Discussões Conclusões Referências

RESUMO - No presente trabalho, foram realizadas classificações da cobertura do solo urbano a partir de uma imagem WorldView-2, sendo realizadas para dois níveis de legenda de classificação, contendo respectivamente 11 e 38 classes de cobertura do solo. Para isto, foram utilizados os algoritmos de árvore de decisão *Best First Tree* (BFTree) e *Logistic Model Tree* (LMT). Os resultados foram validados por meio de mapas de verdade de campo da área de estudo, revelando que o algoritmo LMT obteve os melhores resultados em ambos os níveis de detalhamento.

Palavras-chave: classificação de cobertura do solo, sensoriamento remoto urbano, WorldView-2, mineração de dados.

ABSTRACT - In this work, urban land cover classification was performed using a WorldView-2 image, carried out at two legend levels, respectively containing 11 and 38 land cover classes. As classification methods, we used the Best First Tree (BFTree) and Logistic Model Tree (LMT), which correspond to decision tree induction algorithms. The results were validated using data collected on field trips, revealing that the LMT algorithm obtained the best results at both levels of legend. **Keywords**: land cover classification, urban remote sensing, WorldView-2, data mining.

INTRODUÇÃO

A partir de 2007, a humanidade testemunhou a superação do contingente de população rural pelo contingente de população urbana (UNPD, 2014). No caso do Brasil, a população urbana supera o índice de 84% (IBGE, 2013). Portanto, o crescimento populacional urbano é um fenômeno que ocorre com grande rapidez, sendo considerado um processo irreversível. Com isso, as cidades necessitam de uma melhora no planejamento urbano para atender às necessidades dos cidadãos quanto à qualidade de vida, à distribuição equitativa de bens e serviços e à sua inclusão socioeconômica (BRASIL, 2002).

Para contribuir com o desenvolvimento de estudos urbanos voltados ao planejamento das cidades, são necessárias novas fontes de dados. Nesse contexto, o sensoriamento remoto ganha destaque por possibilitar o mapeamento e a atualização cartográfica dessas áreas. A melhora sistemática da qualidade geométrica dos sensores orbitais de alta resolução espacial e o imageamento em vários canais multiespectrais permitem detalhar os alvos urbanos. Esses recursos são requeridos para o mapeamento urbano, pelo fato de as cidades possuírem uma grande diversidade de alvos, geralmente de pequeno e médio porte (Jensen, 2011).

Mas a disponibilização de altas resoluções espaciais e espectrais significaram novos desafios para o sensoriamento remoto, uma vez que o refinamento de ambas as resoluções exige melhores recursos computacionais para o processamento, manipulação e armazenamento dessas imagens. Nesse sentido, o presente trabalho propõe-se a explorar as potencialidades e limitações do sensor WorldView-2 (WV-2) para a classificação de alvos urbanos em diferentes níveis de legenda.

O termo nível de legenda de classificação (em inglês, *legend level*) é amplamente utilizado na literatura para se referir ao nível de detalhamento de uma classificação, expresso

Esta seção apresenta a área de estudo, o aterial e a metodologia utilizada em seu

material e a metodologia utilizada em seu desenvolvimento.

Área de Estudo

A área de estudo situa-se na cidade de Campinas, interior paulista, a qual possui as seguintes características: coordenada central de 22°54'3''S e 47°3'26''W, altitude média de 685 m, superfície de 794,571 km², população estimada em 2015, ano de realização desta pesquisa, de 1.164.098 habitantes e constitui-se no maior polo invariavelmente pelo número de classes constantes da legenda (Herold et al., 2004; Jensen, 2011). Para isso, serão utilizados métodos não paramétricos de classificação de imagens baseados em árvores de decisão.

MATERIAL E MÉTODOS

tecnológico da América Latina (IBGE, 2014).

Um transecto do campus da UNICAMP foi escolhido para a realização do presente trabalho. A área desse campus atinge quase 3,4 mil quilômetros quadrados e está repleta de prédios rodeados por parques e gramados (UNICAMP, 2016).

A diversidade de alvos urbanos, a fácil acessibilidade aos edifícios e a disponibilidade de dados para este local foram as razões para a sua escolha nesta pesquisa (Figura 1).

IMAGEM WV-2 - COMPOSIÇÃO 5R3G2B

Figura 1 – Localização da área de estudo. Fonte: Adaptado de Google (2015).

Dados de Entrada

O trabalho foi realizado a partir de uma imagem orbital do sensor WorldView-2 adquirida em 02/07/2010, com angulação de 6,75° off nadir, 38,37° de elevação solar e 0% de cobertura de nuvens. Este sensor possui resolução espacial no nadir de 0,46 m no modo pancromático e 1,84 m no multiespectral. As imagens são quantizadas em 11 bits de resolução radiométrica e possui, além dos canais espectrais convencionais do azul (450-510 nm), verde (510-580 nm), vermelho (630-690 nm) e infravermelho próximo (750-745 nm), bandas adicionais do azul costeiro (400-450 nm), amarelo (585-625 nm), vermelho limítrofe (705-745 nm) e infravermelho próximo 2 (860-1040 nm) (DIGITALGLOBE, 2009).

Fluxograma Metodológico

A Figura 2 apresenta o fluxograma metodológico deste trabalho. As etapas de pré-processamento, extração de atributos e segmentação da imagem (WV-2) foram realizadas no trabalho de Anjos (2016).



Figura 2 - Fluxograma das etapas metodológicas do trabalho.

O pré-processamento envolve a correção atmosférica, realizada por meio do algoritmo FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes ou "Análise Rápida de Linha de Visão Atmosférica de Hipercubos Espectrais") do ENVI 5.1 (SULSOFT, 2000) e a ortorretificação, realizada por meio da ferramenta "Dispositivo de Ortorretificação" (OrthoEngine) do PCI Geomatics (GEOMATICA, 2014).

Os atributos utilizados foram: Análise por Componentes Principais Principal ou Component Analysis (PCA); Fração de Ruído Mínima ou Minimum Noise Fraction (MNF); Brilho ou Brightness; Modelo Digital de Altura (MDA), que é resultante da subtração entre o Modelo Digital de Superfície (MDS) e o Modelo Digital de Terreno (MDT); quatro Índices de Vegetação por Diferença Normalizada (NDVI), alternando-se as bandas do vermelho e vermelho limítrofe, bem como as bandas do infravermelho próximo 1 e 2; Índice de Vegetação Ajustado ao Solo (SAVI); além de 19 atributos customizados (ACs), obtidos por meio de aritmética de bandas do WV-2, apresentados na Tabela 1 (Anjos, 2016).

As equações apresentadas na Tabela 1 utilizam as seguintes bandas WV-2: B2 - azul (centrada

em 480 nm), B3 - verde (centrada em 545 nm), B4 - amarelo (centrada em 605 nm), B5 vermelho (centrada em 660 nm) e B7 infravermelho próximo (centrada em 832 nm). Estes dados apresentam outras bandas multiespectrais: B1 - azul costeiro (centrada em 425 nm), B6 - vermelho limítrofe (centrada em 725 nm), além de outra banda na região do infravermelho próximo: B8 - infravermelho próximo 2 (centrada em 950 nm).

Com isso, por meio de combinações lineares, outras equações foram adaptadas, perfazendo o total de 19 atributos customizados (Anjos, 2016).

Como foram desenvolvidas classificações da cobertura do solo urbano baseadas em regiões, é necessária a realização da segmentação da imagem. Esse procedimento foi realizado por meio dos recursos avançados do algoritmo de segmentação multirresolução, disponível no *software* eCognition Developer 8.7 (TRIMBLE, 2011).

Após a segmentação, foi executado o algoritmo de ajuste por diferença espectral (*Spectral Difference*), que é utilizado para refinar os resultados da segmentação através da similaridade espectral entre os segmentos vizinhos (DEFINIENS, 2007).

ATRIBUTO	EQUAÇÕES	REFERÊNCIA
MDA	MDA = MDS - MDT	Leonardi (2010)
BRIGHTNESS	$Brightness = \frac{\sum_{i=1}^{n} banda i}{n}$	DEFINIENS (2007)
NDVI 1	NDVI 1 = $\frac{Banda_{832nm} - Banda_{660nm}}{Banda_{632nm} + Banda_{660nm}}$	Rouse et al. (1974)
NDVI 2	$NDVI 2 = \frac{Banda_{832nm} - Banda_{725nm}}{Banda_{832nm} - Banda_{725nm}}$	Adaptado de Rouse et al. (1974)
NDVI 3	NDVI 3 = $\frac{Banda_{950nm} + Banda_{660nm}}{Banda_{950nm} + Banda_{660nm}}$	Adaptado de Rouse et al. (1974)
NDVI 4	NDVI 4 = $\frac{Banda_{950nm} - Banda_{725nm}}{Banda_{950nm} + Banda_{725nm}}$	Adaptado de Rouse et al. (1974)
SAVI	$SAVI = \frac{(1+L)(Banda_{832nm} - Banda_{660nm})}{Banda_{822nm} + Banda_{660nm} + L}$	Huete (1988)
AC 1	$AC 1 = \frac{Brightness + Banda_{480nm}}{Banda_{660nm}}$	Leonardi (2010)
AC 2	$AC 2 = \frac{Brightness + Banda_{480nm}}{Banda_{725nm}}$	Adaptado de Leonardi (2010)
AC 3	$AC = Brightness + Banda_{480nm} - Banda_{660nm}$	Adaptado de Leonardi (2010)
AC 4	$AC 4 = Brightness + Banda_{480nm} - Banda_{725nm}$	Adaptado de Leonardi (2010)
AC 5	$AC 5 = Brightness - Banda_{832nm}$	Adaptado de Leonardi (2010)
AC 6	$AC 6 = Brightness - Banda_{950nm}$	Adaptado de Leonardi (2010)
AC 7	AC 7 = $\frac{Banda_{660nm}}{Banda_{922nm}}$	Richardson & Wiegand (1977)
AC 8	$AC 8 = \frac{Banda_{725nm}}{Banda_{832nm}}$	Adaptado de Richardson & Wiegand (1977)
AC 9	$AC 9 = \frac{Banda_{660nm}}{Banda_{950nm}}$	Adaptado de Richardson & Wiegand (1977)
AC 10	$AC \ 10 = \frac{Banda_{725nm}}{Banda_{950nm}}$	Adaptado de Richardson & Wiegand (1977)
AC 11	$AC 11 = \frac{Banda_{545nm}}{Banda_{832nm}}$	Bausch & Duke (1996)
AC 12	$AC 12 = \frac{Banda_{725nm}}{Banda_{832nm}}$	Adaptado de Bausch & Duke (1996)
AC 13	AC 13 = $\frac{Banda_{832nm} - Banda_{545nm}}{Banda_{822nm} + Banda_{545nm}}$	Gitelson et al. (1996)
AC 14	$AC 14 = \frac{Banda_{950nm} - Banda_{545nm}}{Banda_{950nm} + Banda_{545nm}}$	Adaptado de Gitelson et al. (1996)
AC 15	$AC 15 = \frac{Brightness + Banda_{425nm}}{Banda_{660nm}}$	Adaptado de Rouse et al. (1974)
AC 16	$AC 16 = \frac{Brightness + Banda_{425nm}}{Banda_{725nm}}$	Adaptado de Leonardi (2010)
AC 17	$AC 17 = Brightness + Banda_{480nm} - Banda_{725nm}$	Adaptado de Leonardi (2010)
AC 18	$AC 18 = Brightness + Banda_{480nm} - Banda_{832nm}$	Adaptado de Leonardi (2010)
AC 19	$AC 19 = \frac{Banda_{545nm} - Banda_{832nm}}{Banda_{545nm} + Banda_{832nm}}$	Jain et al. (2006) Sarkar et al. (2012)

Tabela 1 - Atributos utilizados nas classificações.

Classificação da Imagem WV-2

Primeiramente, é necessária a definição das classes de interesse, sua estruturação em diferentes níveis de legenda e as respectivas chaves de interpretação. Neste sentido, a hierarquia de classes de cobertura do solo urbano foi apresentada no trabalho de Anjos (2016). A Tabela 2 apresenta os níveis de legenda de classificação utilizados neste trabalho.

		_			
	Nível 1	Nível 2 – WV-2			
-	Solo Exposto	Solo Exposto			
	Dissing	Piscina de Azulejo			
	Piscina	Piscina de Vinil			
	Lago	Lago			
	Vegetação Rasteira	Vegetação Rasteira			
	Vegetação Arbórea	Vegetação Arbórea			
	Pavimentação Não	Carvão Coque			
	Viária	Pedra Mineira			
		Asfalto			
	Pavimentação Viária	Asfalto Pintado de Branco			
	i avimentação viaria	Asfalto Pintado de Vermelho			
		Bloquete			
		Arg. de Cimento			
		Arg. de Cimento Pint. Vermelho			
	Materiais Mistos	Arg. de Cimento Pint. Verde			
	(Pavimentação e	Concreto Pint. Amarelo			
	Cobertura	Concreto Pint. Vermelho			
s		Concreto			
ISSe		Concreto Impermeabilizado			
Cla		Vidro Aramado			
		Fibra de Vidro			
		Pastilha Esmaltada			
		Fibrocimento CRFS ¹			
		Fibrocimento com Amianto			
	e Coberturas	Policarbonato			
	Diversas)	Acrílico			
		Plástico			
		Lona			
		Manta Asfáltica Aluminizada			
	Coberturas Metálicas	Aço Galvanizado Brilhante			
		Aço Galvanizado com Ferrugem			
		Aço Galvanizado Fosco			
		Galvalume A ²			
		Galvalume B ³			
		Galvalume C ⁴			
	Coberturas	Cerâmica Iluminada			
	Cerâmicas	Cerâmica Escura			
	Sombra	Sombra			

Tabela 2. Níveis de legenda de classificação da cobertura do solo urbano.

Cabe destacar o significado de alguns tipos de coberturas presentes na Tabela 2. A sigla CRFS, que significa Cimento Reforçado com Fios Sintéticos, corresponde a um tipo de telha de fibrocimento visivelmente semelhante às telhas de fibrocimento com amianto, sem possuí-lo em sua composição. Os diferentes tipos de galvalume representam coberturas metálicas compostas ou recobertas por camadas de alumínio, zinco e silício, que foram divididos em três tipos: A – ondulado com pintura eletrostática branca, B – trapezoidal sem pintura, C – ondulado sem pintura (Anjos, 2016).

O passo seguinte é a extração de amostras para a posterior mineração dos dados e a construção das árvores de decisão. As amostras foram importadas no formato CSV para o *software* WEKA (*Waikato Environment for Knowledge Analysis*), versão

3.7.12 (University of Waikato, 2010). As amostras das classes com os atributos foram utilizadas como conjunto de treinamento para a indução das árvores de decisão e a classificação dos dados. O processo de mineração de dados desse software consiste na aplicação de algoritmos de Aprendizado de Máquina (Machine *Learning*) para а classificação, agrupamento regressão, ou seleção de atribu-tos dos dados, dentre outros (Hall et al., 2009).

Algoritmos de Árvore de Decisão

Os algoritmos de indução de árvores de decisão utilizados foram o *Best First Tree* – BFTree (Shi, 2007) ou "Primeira Melhor Árvore" e *Logistic Model Tree* – LMT ou "Árvore de Modelo Logístico" (Landwehr et al., 2005). Estes algoritmos estão implementados no *software* WEKA.

O algoritmo de indução de árvores de decisão BFTree, proposto por Shi (2007), baseia-se na heurística best first, a qual utiliza o conhecimento sobre o domínio do problema para encontrar soluções mais eficientes do que no caso de busca cega (Witten & Frank, 2000). Em cada nó interno da árvore, é utilizado apenas um atributo como teste. atributos numéricos Tanto para como categóricos, a divisão é binária. Os atributos numéricos são divididos por meio de limiares, tratamento enquanto 0 dos atributos categóricos é dependente do número de classes, isto é, em problemas de duas classes, em que os nós são representados por agrupamento em dois conjuntos, e em problemas de múltiplas classes, nos quais é utilizado um método heurístico de busca, que atinge um compromisso entre a redução da impureza e a velocidade de busca (Shi, 2007; Basgalupp, 2010).

O algoritmo LMT combina regressão logística e aprendizagem de árvore de decisão. A regressão logística é entendida como uma técnica estatística que objetiva produzir um modelo de predição de valores. A partir de um conjunto de observações, o modelo utiliza uma variável categórica, frequentemente binária, para representar uma série de variáveis contínuas e/ou binárias. Os modelos de regressão logística permitem selecionar os atributos relevantes de forma natural. Em comparação com as técnicas mais conhecidas de regressão, sobretudo a linear, a regressão logística distingue-se pelo fato de a variável resposta ser categórica (Landwehr et al., 2005; Witten & Frank, 2000). Nesse contexto, a característica marcante da árvore de decisão gerada pelo algoritmo LMT é a sua estrutura com funções de regressão logística nas folhas. Possui em seus nós terminais, ao invés de classes únicas, vetores de variáveis (x_i) e de coeficientes (β_j) de todas as classes. Através desses valores, é possível calcular a função LMT, definida nas Equações 1 e 2.

$$F(x) = x_i'\beta_j, \qquad j = 1, \dots, J,$$
(1)

em que:

$$x_i'\beta_j = \sum_{k=0}^K \beta_{jk} x_{ik},$$
(2)

sendo xi0=1 e xi e βj correspondentes a vetores (coluna) de dimensão (*K*+1), similar ao modelo logístico em estágio único.

Avaliação dos Resultados

A validação estatística dos resultados foi realizada por meio da utilização de mapas de verdade de campo, elaborado por Anjos (2016). A Figura 3 apresenta os mapas de verdade de campo nos dois níveis de detalhamento.

A fim de promover a validação dos resultados das classificações, foram gerados conjuntos de coordenadas aleatórias dentro dos limites da imagem utilizando o software Minitab 17 Statistical Software, com aproximadamente 2.000 pontos aleatórios para cada conjunto de validação do Nível 1 e 3.100 pontos aleatórios para cada conjunto de validação do Nível 2, sendo cada um deles produzido individualmente para cada classificação. Cada conjunto de coordenadas foi importado para o software QGis 2.14.2 (QGIS, 2009), e para cada ponto aleatório foi realizado o cruzamento espacial entre o mapa de verdade de campo e a classificação. O resultado é uma tabela de atributos associando cada ponto aleatório à classe de referência e àquela atribuída pela classificação. Assim, foi possível a geração das matrizes de confusão para o cálculo da exatidão global, índice Kappa, índice Kappa condicional, acurácias do produtor e usuário para cada classe (Congalton & Green, 1999).



Figura 3 - Mapas de verdade de campo da área de estudo para ambos os níveis de legenda (Fonte: Anjos, 2016).

A fim de categorizar o índice Kappa, Landis & Koch (1977) apresentam uma tabela com essa finalidade (Tabela 3). No entanto, os autores advertem que as divisões são arbitrárias, mas são úteis como padrões de referência para a discussão dos resultados.

Para finalizar a avaliação da acurácia das classificações, os resultados foram comparados entre si por meio do teste de significância estatística. Tal procedimento é realizado a fim de verificar se há diferença significante entre os índices Kappa das classificações dentro do intervalo de confiança considerado (Congalton & Green, 2009; Furtado et al., 2013).

Tabela 3.	Categorização o	lo Indice	Kappa.
-----------	-----------------	-----------	--------

Valores	Categorização		
<0	Péssima		
0 - 0,2	Ruim		
0,21 – 0,4	Razoável		
0,41 - 0,6	Bom		
0,61 - 0,8	Muito Bom		
0,81 - 1,0	Excelente		
Fonte: Landis & Koch (1977).			

RESULTADOS

Resultados para o Nível de Legenda 1

A classificação final utilizando o algoritmo BFTree para o Nível de Legenda 1 é apresentada na Figura 4. Os atributos mais utilizados na construção de sua árvore de decisão foram SAVI e o NDVI 1. Esta classificação apresentou índice Kappa de 0,7068 e exatidão global de 75,03%.

A classificação final utilizando o algoritmo LMT para o Nível de Legenda 1 é apresentada na Figura 5. Os atributos mais utilizados foram NDVI 1 e AC 3. Esta classificação apresentou índice Kappa de 0,7549 e exatidão global de 79,28%.

Resultados para o Nível de Legenda 2

A classificação final utilizando o algoritmo BFTree para o Nível de Legenda 2, com 38 classes, é apresentada na Figura 6. O algoritmo selecionou 32 atributos na montagem da árvore de decisão, tendo sido reconhecidos como mais frequentes: o SAVI e o NDVI 1. Esta classificação apresentou índice Kappa de 0,6977 e exatidão global de 72,44%.



Figura 4 - Classificação da imagem WV-2 com o algoritmo BFTree para o Nível de Legenda 1.



Figura 5 - Classificação da imagem WV-2 com o algoritmo LMT para o Nível de Legenda 1.

São Paulo, UNESP, Geociências, v. 37, n. 3, p. 597-609, 2018



Figura 6 - Classificação da imagem WV-2 com o algoritmo BFTree para o Nível de Legenda 2.



Figura 7. Classificação da imagem WV-2 com o algoritmo LMT para o Nível de Legenda 2.

São Paulo, UNESP, Geociências, v. 37, n. 3, p. 597-609, 2018

Legendu I.				
Classes	Algoritmo BFTree		Algoritmo LMT	
Classes	Ku	Kp	Ku	K _p
Coberturas Cerâmicas	0,2050	0,4916	0,0615	0,1551
Coberturas Metálicas	0,8109	0,7775	0,9118	0,7539
Coberturas Diversas	0,5525	0,8517	0,5699	0,8395
Lago	0,6964	1,0000	0,9671	1,0000
Pavimentação Não Viária	0,5684	1,0000	0,2902	0,8307
Pavimentação Viária	0,7876	0,7092	0,7237	0,6812
Piscina	0,4987	0,3322	1,0000	1,0000
Solo Exposto	0,7959	0,5154	0,4543	0,6408
Sombra	0,6098	0,6422	0,8003	0,6805
Vegetação Arbórea	0,8271	0,4404	0,7723	0,7158
Vegetação Rasteira	0,7199	0,7749	0,7691	0,7175

Tabela 3 - Índice Kappa condicional do usuário e produtor referente às classificações dos dados WV-2 para o Nível de Legenda 1

A classificação final utilizando o algoritmo LMT para o Nível de Legenda 2, com 38 classes, é apresentada na Figura 8. O algoritmo utilizou com maior frequência os atributos SAVI, NDVI 1, NDVI 2 e AC17. Esta classificação apresentou índice Kappa de 0,7210 e exatidão global de 74,37%.

Resultados dos Índices Kappa Condicionais e Testes de Hipótese

As Tabelas 3 e 4 apresentam os valores do

DISCUSSÕES

As classes que apresentaram menores índices Kappa condicionais e proporcionam maiores confusões nas classificações foram aquelas que representam materiais visualmente semelhantes. Esta característica é corroborada pela presença de classes muito similares, sobretudo no Nível de Legenda 2, destacandose: diferentes tipos de aço galvanizado, de galvalumes, de amianto, concreto, asfalto. Também, destacam-se as confusões geradas entre classes espectralmente semelhantes, como cerâmica com solo exposto e policarbonato intemperizado com asfalto.

Os algoritmos utilizados neste trabalho apresentam características diferentes. Enquanto o BFTree corresponde a uma árvore de decisão clássica, o LMT consiste em uma árvore de decisão logística, onde seus nós terminais correspondem a funções logísticas para a identificação das classes. Neste sentido, os atributos utilizados foram diferentes, bem como a quantidade dos mesmos selecionada por cada algoritmo.

O algoritmo BFTree utilizou mais atributos

índice Kappa condicional por classe para as classificações realizadas.

Testes de hipóteses Z com nível de significância de 5% foram realizados para comparar as classificações. As comparações resultados em ambos os dos níveis comprovaram que o índice Kappa obtido pelo algoritmo LMT é significantemente maior que o índice Kappa obtido pelo algoritmo BFTree.

para gerar as árvores de decisão no Nível de Legenda 2, pois a quantidade de classes a serem identificadas impacta decisivamente essa característica.

Em geral, o algoritmo LMT criou uma árvore de decisão com somente um modelo logístico para identificar as classes. O número de atributos utilizados nas funções logísticas de cada classe é variável, mas em média são utilizados de sete a oito atributos para a identificação de uma classe.

testes de hipótese comparando Os 0 desempenho dos algoritmos indicaram que o algoritmo LMT apresentou resultado de índice Kappa superior ao BFTree em todos os níveis de dados. Essa superioridade apresentada pelo algoritmo LMT reside na utilização de um modelo de regressão logística ao invés de regressão linear (caso do BFTree) para selecionar os atributos mais relevantes no conjunto de dados. Com isso, é possível obter a estimativa das probabilidades das classes ao invés de simplesmente obter uma única classe no nó terminal da árvore de decisão (Landwehr et al., 2005).

	Algoritmo BFTree		Algoritmo LMT	
Classes				
	K _u	K _p	K _u	
Aço Galvan. Brilhante	0,4191	0,7957	0,3618	0,6061
Aço Galvan. Ferrugem	0,7456	0,0753	0,4981	0,3316
Aço Galvan. Fosco	0,6350	0,5819	0,5817	0,7618
Acrílico	0,1562	0,0331	0,4975	0,3311
Amianto	0,7818	0,8565	0,8215	0,7529
Asfalto	0,6985	0,7989	0,7946	0,6317
Asfalto Pint. Branco	0,3849	0,3849	0,2504	0,1662
Asfalto Pint. Vermelho	0,6109	0,6109	0,8302	0,9072
Bloquete	0,4891	0,1002	0,3510	0,2504
Carvão Coque	0,9696	0,8763	0,8913	0,6660
Cerâmica Escura	0,2426	0,3995	0,6822	0,1979
Cerâmica Iluminada	0,4601	1,0000	0,4154	1,0000
Arg. de Cimento	0,7755	0,3016	1,0000	0,1990
Arg. de Cimento Pint. Verde	1,0000	0,2793	0,8079	0,8487
Arg. de Cimento P. Vermelho	0,7979	0,3449	1,0000	0,9159
Concreto	0,6443	0,4410	0,7368	0,5764
Concreto Impermeab.	0,6774	0,8220	0,7890	0,9458
Concreto Pint. Amarelo	0,8993	0,5605	0,8448	0,5475
Concreto P. Vermelho	0,3304	0,0988	1,0000	0,3481
CRFS	0,4410	0,2828	0,4983	0,7487
Fibra de Vidro	0,7201	0,7628	0,7970	0,9128
Galvalume A	0,7437	0,9250	0,8413	0,9008
Galvalume B	0,9519	0,9519	0,9469	0,8992
Galvalume C	0,6659	0,7995	0,3742	1,0000
Lago	1,0000	0,3224	1,0000	0,8567
Lona	0,2844	1,0000	0,1959	0,1631
Manta Asf. Alum.	0,8880	0,8880	0,7261	0,7991
Pastilha Esmaltada	0,4982	0,1242	0,5986	0,3737
Pedra Mineira	0,5157	1,0000	0,6471	0,7501
Piscina de Azulejo	0,9150	1,0000	0,7731	1,0000
Piscina de Vinil	0,5546	1,0000	0,7995	0,6660
Plástico	0,7302	0,4192	0,9493	0,5551
Policarbonato	-0,0081	-0,0063	0,0256	0,0157
Solo Exposto	0,4253	0,1498	0,6351	0,4947
Sombra	0,6936	0,8832	0,6225	0,8503
Vegetação Arbórea	0,7596	0,9096	0,7012	0,8601
Vegetação Rasteira	0,6215	0,9022	0,6444	0,8386
Vidro Aramado	0,4123	0,7451	0,9873	0,8862

Tabela 4. Índice Kappa condicional do usuário e produtor referente às classificações dos dados WV-2 para o Nível deLegenda 2.

Quanto ao processo de poda, ambos os algoritmos utilizam a validação cruzada. A validação cruzada é utilizada para combinar o crescimento da árvore com a seleção do número de expansões realizadas. Mesmo utilizando processos de poda baseados em um mesmo conceito, as árvores de decisão geradas pelo algoritmo LMT são bem menores quando comparadas com o algoritmo BFTree. Landwehr et al. (2005) credita as maiores acurácias geradas pelas classificações utilizando o algoritmo LMT ao processo de poda, por este utilizar validação cruzada, bem como a adoção do uso de modelos de regressão logística.

Outro aspecto em relação ao desempenho

dos algoritmos é a diferença dos índices Kappa interníveis. Ambos os algoritmos obtiveram melhores índices Kappa no Nível de Legenda 1, pois este nível contempla apenas onze classes de cobertura do solo. Ao passo que o número de classes aumenta, caso do Nível de Legenda 2, o desempenho dos algoritmos sofre uma piora

O presente trabalho comparou classificações de cobertura do solo urbano a partir de uma cena WorldView-2 utilizando os algoritmos de árvore de decisão BFTree e LMT em dois níveis de legenda de classificação. respectivamente com 11 e 38 classes de cobertura do solo. As classificações para ambos os níveis apresentaram exatidão global acima de 70% e índices Kappa oscilando entre 0,7068 e 0,7863 no Nível de Legenda 1, e entre 0,6977 e 0,7210 no Nível de Legenda 2. Os testes de hipótese demonstraram que os resultados

significante.

Qualquer algoritmo apresenta dificuldades para identificar um número elevado de classes. O Nível de Legenda 2 contempla 38 classes. Aí está a justificativa para o menor desempenho de ambos algoritmos no nível de detalhamento mais refinado.

CONCLUSÕES

LMT alcançados pelo algoritmo foram significantemente superiores aos resultados obtidos pelo algoritmo BFTree.

Os resultados alcançados comprovam que as imagens orbitais que conciliam altas resoluções espaciais e espectrais são adequadas para a identificação das classes de cobertura do solo urbano em nível de legenda extremamente detalhado. Também, a utilização de algoritmos de mineração de dados, como as árvores de decisão, colabora efetivamente na melhora da acurácia destas classificações.

AGRADECIMENTOS

Os autores gostariam de expressar a sua gratidão às empresas DigitalGlobe, na pessoa do Sr. Roberto Varela, e Satmap, na pessoa do Sr. Weber Pires, pela gentil cessão da imagem WorldView-2. Da mesma forma, expressam seus agradecimentos a CAPES pela concessão da bolsa de mestrado ao primeiro autor, cuja pesquisa de dissertação se encontra sumariada neste artigo.

REFERÊNCIAS

- ANJOS, C.S. Classificação de áreas urbanas com imagens multiespectrais e hiperespectrais utilizando métodos não-paramétricos. São José dos Campos, 2016. Tese (Doutorado em Sensoriamento Remoto), Instituto Nacional de Pesquisas Espaciais.
- BASGALUPP, M.P. LEGAL-Tree: um algoritmo genético multi-objetivo lexicográfico para indução de árvores de decisão. São Carlos, 2010. Tese (Doutorado em Ciências da Computação e Matemática Computacional), Instituto de Ciências Matemáticas e Computação (ICMC-USP).
- BAUSCH, W.C. & DUKE, H.R. Remote sensing of plant nitrogen status in corn. Transactions of the ASAE, v. 39, n. 5, p. 1869-1875, 1996.
- BRASIL. Estatuto da Cidade e Legislação Correlata. Lei nº 10.257, de 10 de junho de 2001 - 2. ed.-Brasília: Senado Federal, Subsecretaria de Edições Técnicas, 80p., 2002. ISBN 85-7018-223-6
- CONGALTON, R.G. & GREEN, K. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. Boca Raton: Lewis Publishers, 1999.
- CONGALTON, R.G. & GREEN, K. Assessing the accuracy of remotely sensed data: principles and practices. 2 ed. Boca Raton: CRC Press, 183p., 2009.
- DEFINIENS. Definiens Developer 7: Reference Book. Munique: Definiens AG, 2007. 195 p. Disp. em: http://www.ecognition.cc/download/ReferenceBook.pdf.
- DIGITALGLOBE. WorldView-2 Data Sheet. 2009. 2 p. Disp. <https://www.digitalglobe.com/sites/default/files/DG em: _WorldView2_DS_PROD.pdf>.
- SULSOFT. Guia do ENVI em Português. Sulsoft, 2000. Disp.em www.sulsoft.com.br. Acesso em 15 out. 2006.

FURTADO, L.F.A.; FRANCISCO, C.N.; ALMEIDA, C.M.

Análise de Imagem Baseada em Objeto para Classificação das Fisionomias da Vegetação em Imagens de Alta Resolução Espacial. Geociências, São Paulo, v. 32, n. 3, p. 441-451, 2013.

- GEOMATICA. PCI Geomatics Announces Release of Geomatica 2014. GATINEAU, Quebec, Canada: [s.n.], 2014. 5p. Disp. em: http://www.pcigeomatics.com/pressnews/2014.
- GITELSON, A.A.; KAUFMAN, Y.J.; MERZLYAK, M.N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. Remote Sensing of Environment, v. 58, n. 3, p. 289-298, 1996.
- HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The WEKA data mining software. [S.l.: s.n.], 10p., 2009.
- HEROLD, M.; ROBERTS, D.A.; GARDNER, E.M.; DENNISON, P.E. Spectrometry for urban area remote sensing – Development and analysis of a spectral library from 350 to 2400 nm. Remote Sensing of Environment, v. 91, p. 304-319, 2004.
- HUETE, A.R. A soil-adjusted vegetation index (SAVI). Remote Sensing of Environment, v. 25, p. 53-70, 1988.
- IBGE. Atlas do Censo Demográfico 2010. Rio de Janeiro: IBGE, 2013. 156 p.
- IBGE. Cidades@ Consulta por Município. 2014. Disp. em: <http://cod.ibge.gov.br/232TL>.
- JAIN, S.K.; SARAF, A.K.; GOSWAMI, A.; AHMAD, T. Flood inundation mapping using NOAA AVHRR data. Water Resources Management, v. 20, n. 6, p. 949-959, 2006
- JENSEN, J.R. Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. São José dos Campos: Parêntese, 2011. Tradução José Carlos Neves Epiphanio (coord.).

- LANDIS, J.R. & KOCH, G.G. The measurement of observer agreement for categorical Data. **Biometrics**, v. 33, n. 1, p. 159–174, 1977.
- LANDWEHR, N.; HALL, M.; FRANK, E. Logistic model trees. **Mach. Learn**, v. 59, n. (1-2), p. 161-205, 2005.
- LEONARDI, F. Abordagens cognitivas e mineração de dados aplicadas a dados ópticos orbitais e de laser para classificação de cobertura do solo urbano. São José dos Campos - SP, 2010. Dissertação (Mestrado), Instituto Nacional de Pesquisas Espaciais.
- QGIS Development Team, **QGIS Geographic Information System**. Open Source Geospatial Foundation, 2009. URLhttp://qgis.osgeo.org.
- RICHARDSON, A.J. & WIEGAND, C. Distinguishing vegetation from soil background information. Photogrammetric Engineering and Remote Sensing, v. 43, p. 1541-1552, 1977.
- ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W.; HARLAN, J.C. Monitoring the vernal advancement of retrogradation of natural vegetation. Greenbelt: NASA/GSFC, 371p., 1974.
- SARKAR, A.; GARG, R.D.; SHARMA, N. RS-GIS Based Assessment of River Dynamics of Brahmaputra River in

India. Journal of Water Resource and Protection, v. 4, n. 02, p. 63-72, 2012.

- SHI, H. **Best-first decision tree learning**. Hamilton, NZ, 2007. Master's thesis. University of Waikato.
- TRIMBLE. eCognition Developer 8.7 User Guide. Munich, Germany: [s.n.], 2011. 258p. Disp. em: http://www.ecognition.com/>.
- UNICAMP. A Unicamp. 2016. Disp. em: < http://www. unicamp.br/unicamp/a-unicamp>.
- UNIVERSITY OF WAIKATO. Weka 3.7.12 Machine Learning Software in Java. Disp. no site da University of Waikato 2010. URL: http://www.cs.waikato.ac.nz/ml/weka.
- UNPD. World Urbanization Prospects: The 2014 Revision. [sn], 2014. 493p. Disp. em: http://esa.un.org/unpd/wup/ Publications/Files/WUP2014-Report.pdf>.
- WITTEN, I.H. & FRANK, E. Data mining: Practical machine learning tools and techniques with JAVA implementations. San Francisco: Morgan Kaufmann, 371p., 2000.

Submetido em 27 de julho de 2017 Aceito em 5 de março de 2018