

Classificação orientada a objeto em associação às ferramentas reflectância acumulada e mineração de dados

Thallita Oliveira de Grande⁽¹⁾, Tati de Almeida⁽²⁾ e Rejane Ennes Cicerelli⁽²⁾

⁽¹⁾Universidade de Brasília, Instituto de Ciências Biológicas, Programa de Pós Graduação em Ecologia, Campus Universitário Darcy Ribeiro, Bloco E, Asa Norte, CEP 70910-900 Brasília, DF, Brasil. E-mail: tata9go@hotmail.com ⁽²⁾Universidade de Brasília, Instituto de Geociências, Campus Universitário Darcy Ribeiro, Asa Norte, CEP 70910-900 Brasília, DF, Brasil. E-mail: tati_almeida@unb.br, rejaneig@unb.br

Resumo – O objetivo deste trabalho foi utilizar as técnicas de reflectância acumulada e mineração de dados, seguidas por classificação orientada a objeto, em imagens do sensor Operational Land Imager (OLI), satélite Landsat 8, para a classificação de vegetação nativa e cobertura agropecuária do Cerrado. Quatro imagens de reflectância foram utilizadas para a discriminação de seis classes – agricultura, pecuária, campo limpo úmido, savana, floresta e campo –, para a classificação do Parque Nacional das Emas, no Estado de Goiás, e adjacências. As imagens foram segmentadas para a extração de atributos espectrais de amostras e a aplicação de combinações de atributos (média + moda, todos os atributos) na mineração de dados. O programa Weka foi utilizado para a construção das árvores de decisão. Essa metodologia indicou que a diferenciação entre alvos aumentou a partir da acumulação temporal da reflectância, em todas as bandas e as classes, e a melhor imagem foi aquela do somatório das quatro datas. A classificação baseada na associação de atributos média + moda não apresentou impedimentos no processamento das regras de decisão, diferentemente da associação de todos os atributos. A classificação média + moda apresentou acurácia satisfatória (exatidão global, 69%; Kappa, 58%; e TAU, 63%). A integração dessas técnicas apresenta potencial para a diferenciação de vegetação nativa e antrópica do Cerrado.

Termos para indexação: análise baseada em objeto, análise multitemporal, antropização, classificação supervisionada, mineração, sensoriamento remoto.

Object-oriented classification in association with accumulated reflectance and data mining tools

Abstract – The objective of this work was to use the accumulated reflectance technique and data mining application, followed by object-oriented classification, in images of Operational Land Imager (OLI) sensor, Landsat 8, for the classification of native vegetation and agricultural coverage of Cerrado. Four reflectance images were used for the discrimination of six classes – agriculture, livestock, wetland, savannah, forest, and grassland –, for classification of Parque Nacional das Emas and surrounding areas in the state of Goiás, Brazil. The images were segmented for the extraction of sample spectral attributes and application of attribute combinations (mean + mode, all attributes) on data mining. The Weka software was used to construct the decision trees. This methodology indicated that the differentiation among targets increased from the temporal accumulation of the reflectance in all bands and classes, and that the optimal image was that of the sum of the four dates. The classification based on the attribute associations mean + mode showed no restraints in the decision rules processing, unlike the association of all attributes. The mean + mode classification showed a satisfactory accuracy (global accuracy, 69%; Kappa, 58%; and TAU, 63%). The integration of these techniques shows potential to differentiate native and anthropogenic vegetation in the Cerrado.

Index terms: object-based analysis, multitemporal analysis, anthropization, supervised classification, mining, remote sensing.

Introdução

A extração de informações automáticas de dados de sensoriamento remoto, em que o intérprete tem o mínimo de interferência no processo, vêm permitindo a aquisição de dados espaciais precisos e acurados (Arvor

et al., 2013). Um exemplo desse tipo de processamento é a classificação orientada a objetos geográficos, que se baseia na segmentação e classificação supervisionada ou não, para fornecer subsídios à interpretação de imagens de sensoriamento remoto (Fernandes et al., 2012; Novack et al., 2014). Nessa classificação, a

distinção entre alvos não se resume às características espectrais dos pixels, uma vez que são usados, como unidade de processamento, objetos segmentados com base em características comuns de forma, textura, espectro, vizinhança, geometria, entre outros. Estes atributos são, então, incorporados na classificação (Blaschke, 2010; Marpu et al., 2010; Camargo et al., 2012; Novack et al., 2014).

A mineração de dados pode ser utilizada em conjunto com a técnica de classificação orientada a objeto na automação do processo (Passo et al., 2013). Esse tipo de algoritmo computacional extrai informações de grandes bases de dados e é capaz de definir padrões imperceptíveis ao intérprete humano, mas que podem ser utilizados com sucesso na distinção de classes de informações (Hall et al., 2009). As árvores de decisão, por exemplo, geram definições em formato de árvore, com estrutura hierárquica de regras com nós e ramificações, em que cada nó representa uma decisão sobre um atributo. Essa estrutura pode, então, ser aplicada à definição de regras de decisão das classes, sobre toda a base de dados, no processo de classificação de imagens (Quinlan, 1993).

A utilização de processamento digital de imagens, baseada em conhecimento e funções automáticas de extração de informação, configura algumas das evoluções previstas na classificação de uso e cobertura do solo. Aprimorar essas técnicas e protocolos é essencial em termos sociais e científicos (Nascimento & Sano, 2010), sobretudo quando o enfoque são áreas extensas como o Cerrado, que apresenta particularidades que configuram barreiras à distinção das classes de uso e cobertura da terra (Brannstrom et al., 2008). No Cerrado, a natural heterogeneidade forma um gradiente espacial entre fitofisionomias campestres e florestais (Pinheiro & Durigan, 2009), cuja separabilidade não é algo trivial de ser alcançado, uma vez que as diferentes formações não se distinguem espacialmente de forma categórica e têm, além disso, respostas espectrais semelhantes (Sano et al., 2010). O avanço da agropecuária sobre o bioma é outra dificuldade, pois classes como pastagens cultivadas e plantações também apresentam respostas espectrais confundidas com as das formações nativas (Sano et al., 2010).

Estas características impõem ao contexto do Cerrado um desafio permanente no processo de classificação, para que o mapeamento alcance efetividade (DeFries & Chan, 2000). Trabalhos apresentados por Nascimento

& Sano (2010) e Hermuche & Sano (2011) indicam a utilização de imagens de reflectância espectral acumulada no Cerrado, para o aumento da capacidade de discriminação entre os alvos da superfície terrestre. Tais estudos sugerem pesquisas adicionais para maior compreensão da aplicação da técnica.

Supõe-se que o desempenho dos processos automatizados da classificação orientada a objeto possa ser aprimorado com a adoção da reflectância acumulada como dado de entrada, e que a mineração de dados possibilite a sistematização e a definição de padrões consistentes para aumentar o potencial do classificador. A aplicação desse conjunto de ferramentas deverá captar os limiares sutis de diferenciação de classes de informação do Cerrado.

O objetivo deste trabalho foi utilizar as técnicas de reflectância acumulada e mineração de dados, seguidas por classificação orientada a objeto, em imagens do sensor Operational Land Imager (OLI), satélite Landsat 8, para a classificação de vegetação nativa e cobertura agropecuária do Cerrado.

Material e Métodos

A área utilizada neste estudo foi o Parque Nacional das Emas (18°07'17"S, 52°54'54"W), no sudoeste goiano, e suas adjacências utilizadas por atividades agropecuárias (Plano..., 2004). Utilizaram-se quatro cenas de reflectância na superfície terrestre ortorretificadas, do sensor OLI do Landsat 8, disponíveis na página do U.S. Geological Service (2016), tomadas em 18/07/2013 (D1), 03/08/2013 (D2), 19/08/2013 (D3) e 11/02/2014 (D4). Para a seleção das cenas, levou-se em consideração a cobertura de nuvens inferior a 10% e a maior abrangência sazonal, na tentativa de incorporar as marcadas variações sazonais do Cerrado. A reflectância acumulada foi obtida por soma aritmética simples das cenas, banda a banda, no programa Envi 5.1, de modo que: $A1 = D1$; $A2 = D1+D2$; $A3 = D1+D2+D3$; e $A4 = D1+D2+D3+D4$.

Com base em classificações prévias da área (Plano..., 2004), na experiência de campo dos autores na região e no apoio de imagens de alta resolução espacial, selecionou-se uma área de tamanho fixo ($5 \times 5 = 25$ pixels) para cada classe de informação, no intuito de amostrar as características das distintas reflectâncias. A definição das classes seguiu a proposta de Ribeiro & Walter (1998) para as formações florestais, campestres e savânicas, que foram denominadas genericamente,

no presente trabalho, como floresta, campo e savana, respectivamente. A classe campo limpo úmido foi considerada na tentativa de discriminá-la em relação às demais formações campestres, pois ela se caracteriza por ter o lençol freático próximo à superfície e por ser contígua aos rios e áreas inundadas periodicamente. Além disso, também foram inseridas classes de uso da terra com ocupação antrópica, nomeadas de agricultura e pecuária (Manual..., 2012). Essas classes foram estabelecidas seguindo-se o limite de detecção das imagens Landsat, fator determinante na escala de trabalho. A partir da definição das classes e seleção dos elementos amostrais, obteve-se a média da reflectância para cada classe, tanto por banda quanto por datas individuais e acumuladas.

Uma análise de variância fatorial de medidas repetidas foi aplicada, por bandas, para testar se a reflectância diferia significativamente entre os níveis de acumulação das datas, e se o efeito da acumulação temporal estava presente dentro de cada classe (classe como fator residual). Posteriormente, aplicou-se o teste t de comparação múltipla pareada (com p ajustado pelo método Holm), para detectar o intervalo dos níveis de acumulação das datas em que as reflectâncias acumuladas foram mais discrepantes (Crawley, 2013). Os dados de reflectância foram utilizados em forma de logaritmo, para se alcançar as premissas de normalidade e homocedasticidade de variâncias ($\alpha < 0,05$). As análises foram realizadas pelo programa R v. 3.2.4 (R Core Team, 2016).

Sobre a imagem de reflectância acumulada das quatro datas, realizou-se a aplicação da metodologia de "endmembers" para a eliminação dos ruídos, tal qual utilizada por Hermuche & Sano (2011). Como explica Carvalho Júnior et al. (2007), essa metodologia consiste das seguintes etapas: redução da dimensão espectral da imagem ("Minimization Noise Fraction" – MNF) (Green et al., 1988); redução da dimensão espacial da imagem ("Pixel Purity Index" - PPI); e projeção espacial dos dados, em um escatergrama n-dimensional. Essa rotina foi aplicada pelo programa Envi 5.1 (Spectral Hourglass Wizard). Após 5.000 iterações, a dimensionalidade dos dados foi reduzida para os três primeiros MNFs (componentes) que, posteriormente, foram redistribuídos em sete bandas (Carvalho Júnior et al., 2007; Hermuche & Sano, 2011).

Em seguida, realizou-se a segmentação da imagem do somatório das quatro datas, processada em três dimensões e redistribuída em sete bandas, utilizada

como dado de entrada no programa InterIMAGE 4.2. Utilizou-se o segmentador proposto por Baatz & Schäpe (2000) e os parâmetros descritos na Tabela 1 (Antunes et al., 2015). Selecionaram-se 82 elementos amostrais para treinamento do classificador, que foram distribuídos, entre as seis classes, em locais mais representativos.

Dentro de uma gama de atributos de variadas naturezas disponíveis pelo programa InterIMAGE, extraíram-se os atributos espectrais relevantes para refletir o possível efeito da acumulação da reflectância nas análises. Assim, foram obtidos, por banda e por classe, os seguintes atributos espectrais: média (valor médio de pixels), pixmáx (valor de pixel máximo por banda), pixmín (valor de pixel mínimo por banda), amplitude (diferença entre os valores máximos e mínimos de pixel por banda), moda (valor mais frequente de pixels por banda) e soma (somatório dos valores de pixel por banda).

No programa Weka 3.6, executou-se a mineração dos dados supracitados com o algoritmo J48 (Antunes et al., 2015), tendo-se considerado para cada atributo, separadamente, as amostras de todas as classes juntas. Deste modo, para cada atributo foi obtida uma árvore de decisão e suas respectivas estatísticas. Os melhores atributos foram aqueles que ofereceram o menor número de caminhos para a identificação das classes e a árvore com o menor tamanho e número de ramos. Houve a repetição da mineração de dados para as

Tabela 1. Parâmetros utilizados na segmentação para a coleta de amostras e na classificação orientada a objeto da imagem Landsat 8 de reflectância acumulada, do Parque Nacional das Emas e adjacências, Goiás.

Parâmetros	Segmentação para coleta de amostras	Classificação
Operador TopDown	TA Baatz Segmenter	TA Baatz Segmenter
Bandas	0,1,2,3,4,5,6	0,1,2,3,4,5,6
Peso de bandas	1,1,1,1,1,1	1,1,1,1,1,1
Compacidade	0.5	0.5
Cor	0.5	0.5
Escala	1000	100
Otimização	Não	Não
Confiabilidade	0.2	0.2
Distância euclidiana	20	20
Operador BottomUp ⁽¹⁾	Dummy BottomUp	Dummy BottomUp
Ponto de parada	Nenhum	Nenhum

⁽¹⁾Os demais parâmetros foram utilizados de acordo com o padrão (default) do programa: regra de decisão BottomUp: All, Spatial Resolve; Multi classes TopDown: desmarcado.

associações dos atributos média + moda e de todos os atributos juntos.

Por fim, realizou-se a classificação TopDown orientada a objeto da imagem de reflectância acumulada, pelo programa InterIMAGE 4.2 (Baatz & Schäpe, 2000; Passo et al., 2013), com base nos parâmetros supracitados. As regras de decisão de cada nó (classes) da rede semântica foram construídas com base na árvore de decisão, gerada pela mineração de dados da associação de atributos média + moda, uma vez que o programa não conseguiu executar as regras de decisão da classe pecuária, gerada pela associação de todos os atributos juntos, o que será discutido posteriormente.

A estimativa da exatidão da classificação foi realizada por meio da aplicação da metodologia proposta por Congalton & Green (1999), em que uma matriz de confusão (quadrada) é construída com elementos amostrais, atribuídos às classes do mapa a partir de duas classificações (a real e a de referência/verdade de campo). De acordo com o método, um número de elementos amostrais de verificação da exatidão da classificação é determinado pelo valor de uma distribuição qui-quadrado, seu grau de liberdade, o número de classes, um nível de confiança, a proporção da classe com maior área no mapa e um erro máximo. Considerou-se o erro admissível de 0,1, tendo-se obtido $N = 126$ pontos amostrais distribuídos aleatoriamente na área, com uso da ferramenta “Random Selection”, da extensão Hawth’s Analysis Tools, do programa ArcGIS, versão 10.2.1 (Environmental Systems Research Institute, Redlands, CA, EUA). Nos casos de dúvidas, a verificação foi realizada por meio das cenas de imagens RapidEye do ano de 2013 (Brasil, 2015) e do Google Earth do ano de 2014.

Estes dados foram utilizados como dados de referência (verdade de campo) para a construção da matriz de confusão. Finalmente, aplicaram-se três dos principais coeficientes de concordância para a avaliação da acurácia da classificação: o índice de exatidão global (Po), Kappa e TAU (Congalton & Green, 1999).

Resultados e Discussão

Os resultados obtidos na distinção dos alvos, com uso de reflectância acumulada de agricultura, pecuária, campo limpo úmido, campo, floresta e savana, mostraram que a reflectância diferiu significativamente

entre os níveis de acumulação das datas, para todas as bandas, e que este efeito se fez presente dentro de cada classe (Tabela 2), como pode ser exemplificado pela Figura 1, para a banda 4 do Landsat 8. Resultados similares foram obtidos por Nascimento & Sano (2010) e Hermuche & Sano (2011), o que indica que essa técnica permite maior diferenciação espectral entre os alvos analisados.

O melhor nível de distinção foi o que resultou do somatório das quatro datas. Como pontuado por Nascimento & Sano (2010), quanto mais cenas consideradas, maior é a capacidade de discriminação entre alvos. Embora tenham sido detectadas diferenças significativas da reflectância acumulada, entre todos os pares de níveis de acumulação de datas e para todas as bandas, as maiores diferenças ocorreram entre os níveis A1-A4, A2-A3 e A2-A4 (Tabela 2). Supõe-se que as diferenças significativas obtidas nos níveis A1-A4 e A2-A4 decorreram da inserção da cena da estação chuvosa (D4-11/02/2014) na composição de A4, em que os alvos analisados apresentam maior variação espectral em relação à estação seca.

A banda 5 foi a que mais se destacou quanto à diferenciação entre os níveis de acumulação das datas ($F_{(3,15)} = 1013,0$, $p < 0,001$). Nascimento & Sano (2010) também encontraram resultado semelhante para a banda do infravermelho médio, e isto pode ser atribuído ao fato de estas serem as bandas que melhor caracterizam a resposta espectral de alvos vegetados, como os do presente estudo.

As classes campo e campo limpo úmido mostraram, tanto em relação à reflectância individual quanto à acumulada, ter respostas espectrais parecidas, o que denota a dificuldade de diferenciação desses alvos e serve de alerta para posteriores estudos que almejem diferenciá-los com exatidão. Assim como também sugerido por Nunes & Roig (2015), para a relação entre as classes campo e savana, os campos limpos úmidos, apesar de suas particularidades hídricas, podem se comportar, em termos espectrais, de forma similar aos campos, especialmente em estações secas, que são bem definidas em razão da sazonalidade climática, como é o caso do Cerrado.

A Figura 2 e a Tabela 3 mostram, respectivamente, as árvores de decisão das associações de atributos da mineração de dados, obtidas a partir da metodologia proposta, e os atributos que foram explorados e utilizados nas regras de decisão. Os resultados da mineração de dados da associação de todos os atributos

Tabela 2. Comparações, por banda, das reflectâncias acumuladas entre os níveis de acumulação das datas (A1, A2, A3 e A4) das cenas da imagem Landsat 8 do Parque Nacional das Emas e adjacências, Goiás⁽¹⁾.

Datas	Banda 1	Banda 2	Banda 3	Banda 4	Banda 5	Banda 6	Banda 7
	164,6***	173,4***	245,0***	121,7***	1013,0***	157,2***	90,75***
A1-A2	0,00024	0,00031	0,00013	0,00063	$3,9 \times 10^{-6}$	0,00040	0,00135
A1-A3	0,00019	0,00026	0,00013	0,00054	$3,9 \times 10^{-6}$	0,00034	0,00103
A1-A4	0,000051	0,000069	0,000026	0,00019	$1,2 \times 10^{-6}$	0,000082	0,00036
A2-A3	$9,7 \times 10^{-6}$	0,000013	0,000013	0,00003	$1,3 \times 10^{-6}$	0,000012	0,000014
A2-A4	$1,7 \times 10^{-8}$	$2,0 \times 10^{-8}$	$1,2 \times 10^{-7}$	$6,4 \times 10^{-8}$	$1,7 \times 10^{-7}$	$9,7 \times 10^{-8}$	$4,5 \times 10^{-7}$
A3-A4	0,00019	0,00026	0,00013	0,00054	$3,9 \times 10^{-6}$	0,00034	0,00109

⁽¹⁾A1 = D1; A2 = D1+D2; A3 = D1+D2+D3; A4 = D1+D2+D3+D4. ***Significativo a 0,1% de probabilidade, pelo teste $F_{(3,15)}$.




Figura 1. Reflectâncias (ρ) individuais e acumuladas (com erro padrão) da banda 4 (VIS-R) do Landsat 8 para seis classes de uso e cobertura da terra do Parque Nacional das Emas e adjacências, Goiás, oriundas de quatro cenas (D1, 18/07/2013; D2, 03/08/2013; D3, 19/08/2013; e D4, 11/02/2014), cujos somatórios são representados por A1 = D1, A2 = D1+D2, A3 = D1+D2+D3, A4 = D1+D2+D3+D4.




Figura 2. Árvores de decisão geradas pela mineração de dados operada sobre a associação dos atributos espectrais “todos os atributos juntos” (média, pixel máximo, pixel mínimo, amplitude, moda, soma) (A) e “média + moda” (B), provenientes das amostras de segmentos coletados por classe de uso e cobertura da terra na imagem com reflectância acumulada do Parque Nacional das Emas e adjacências, Goiás.

juntos foram considerados, a priori, mais adequados para subsidiar a classificação dos alvos analisados, uma vez que apresentaram o menor tamanho de árvore e de número de ramos, conforme exposto por Camargo et al. (2012) e Novack et al. (2014) (Figura 2 A; Tabela 3).

Entretanto, durante a classificação para esta regra de decisão, o programa InterIMAGE não foi capaz de processar a classe pecuária, o que tornou seu nó inabilitado na rede semântica e, consequentemente, sua classe ausente no respectivo mapa temático. Este fato ocasionou pixels não classificados na porção sudoeste da área. Em testes posteriores, realizados para melhorar a eficácia da discriminação das classes, em que se consideraram mais amostras e atributos de outras naturezas (forma e vizinhança), houve incapacidade de processamento pelo programa InterIMAGE.

Outro ponto a ser ponderado, no que diz respeito às falhas observadas no processamento da classificação, é se a área da imagem utilizada, de aproximadamente 19.500 pixels, teria sido demasiadamente extensa. Apesar de esta área estar dentro dos limites suportados pelo programa, de acordo com seus criadores (Pontificia..., 2012), o aumento da complexidade das regras de decisão inseridas talvez possa relativizar o tamanho da imagem utilizada. Nascimento et al. (2013) também enfrentaram problemas quanto à limitação do tamanho das imagens que podem ser inseridas no sistema e às interrupções abruptas em seu funcionamento, e indicam a necessidade de amadurecimento computacional do programa. Assim como no presente estudo, Passo et al. (2013), compararam outros tipos de classificação com a orientada a objeto, em imagens Wordview II, e

também observaram problemas de processamento no uso do programa, como a incapacidade de lidar com um grande número de segmentos.

Assim, após a realização de vários testes de mineração de dados, operados sobre cada atributo e sobre associações de atributos, executou-se a classificação baseada na associação de atributos média + moda, que não apresentou impedimento no processamento das regras de decisão (Figura 2 B).

A classificação baseada na associação de atributos média + moda apresentou acurácia satisfatória, com índice de exatidão global de 69%, Kappa de 58% e TAU de 63% (Tabela 4). O mapa temático (Figura 3) indicou que as classes savana, floresta e campo apresentaram razoável concordância na classificação. No entanto, a classe campo limpo úmido se confundiu, em muitas regiões, com a classe campo, talvez em razão da sua semelhança espectral observada nos gráficos de reflectância, o que auxiliou a obtenção de coeficientes de concordância menos significativos. Ainda, classes de informações não categorizadas, tais como estradas de terra, também foram incluídas na classe campo, o que indica falhas na construção da legenda, uma vez que tal categoria deveria ser considerada em uma classe denominada outros. A classe agricultura também se mostrou relativamente bem classificada, entretanto, algumas regiões agrícolas foram categorizadas como áreas de pecuária. As poucas áreas realmente dominadas por pecuária foram corretamente classificadas.

Para estudos futuros, recomenda-se testar as regras de decisão em áreas distintas com padrões espectrais similares, ou refiná-las por classe, para encontrar

Tabela 3. Estatística das árvores de decisão geradas pela mineração de dados, operada sobre cada atributo e sobre associações de atributos, provenientes das amostras de segmentos coletados por classe de uso e cobertura da terra na imagem com reflectância acumulada do Parque Nacional das Emas e adjacências, Goiás.

Classe	Número de caminhos que culminam nas classes ⁽¹⁾							
	Média	Pixmáx	Pixmín	Amplitude	Moda	Soma	Média+Moda	Todos
Agricultura (25)	3	3	2	7	3	3	2	1
Pecuária (7)	1	1	1	2	2	1	2	1
Floresta (10)	1	3	1	2	1	2	1	1
Campo (14)	1	2	1	1	1	1	1	1
Campo limpo úmido (14)	2	3	3	4	2	3	2	1
Savana (12)	1	3	1	1	1	3	1	1
Número de ramos	9	15	9	17	10	13	9	6
Tamanho da árvore	17	29	17	33	19	25	17	11

⁽¹⁾Média, valor médio de pixels; pixmáx, valor de pixel máximo por banda; pixmín, valor de pixel mínimo por banda; amplitude, diferença entre os valores máximos e mínimos de pixel por banda; moda, valor mais frequente de pixels por banda; soma, somatório dos valores de pixel por banda; média+moda, atributos média e moda associados; e todos, todos os atributos associados. Número total de amostras coletadas 82.

Tabela 4. Área ocupada por cada classe e índices de verificação da qualidade da classificação TopDown com base na associação de atributos média+moda, da imagem com reflectância acumulada do Parque Nacional das Emas e adjacências, Goiás.

Classe	Área	Porcentagem (%)
Agricultura	511908300	28,89
Campo	582691500	32,89
Floresta	46654200	2,63
Pecuária	102640500	5,79
Savana	205002900	11,57
Campo limpo úmido	322561800	18,20
Total	1771459200	100,00
Índices de verificação de qualidade		
Exatidão global (Po)		0,698
Kappa		0,589
TAU		0,638

um denominador comum que permita aplicá-las genericamente em qualquer paisagem que contenha a classe em questão. A importância de tornar as regras de decisão replicáveis, a fim de aumentar a aplicabilidade da técnica, também é algo sugerido por Camargo et al. (2012), no mapeamento de áreas com características geomorfológicas similares.

Como alternativas para a melhoria dos resultados obtidos, uma possibilidade seria, segundo o trabalho de Carvalho et al. (2014), construir a rede semântica subdividindo-se os nós em nós-filhos, ou refinar os resultados buscando-se manualmente os limiares entre as classes por meio da análise de gráficos de histogramas. Outra possibilidade seria testar diferentes tipos de operadores para cada nó da rede semântica, embora esta alternativa possa acarretar custos operacionais (Novack et al., 2014).




Figura 3. Mapa temático da classificação orientada a objeto baseada nas associações dos atributos média+moda da imagem do Parque Nacional das Emas e adjacências, Goiás.

Conclusões

1. A integração das técnicas de mineração de dados e a classificação orientada a objeto, sobre imagens com reflectância acumulada, apresenta potencial para a diferenciação de vegetação nativa e antrópica do Cerrado.

2. A metodologia é inapropriada para discriminar campo e campo limpo úmido, porém, testes adicionais podem ser realizados com novos arranjos na mineração de dados e classificação orientada a objeto.

3. O programa utilizado para a classificação orientada a objeto apresenta limitações no processamento das árvores de decisão propostas.

Agradecimentos

Ao Dr. Edson Eyji Sano pelas discussões sobre o tema; à Esri e à Imagem (contrato n.º 2011 MLK 8733), pela disponibilização do pacote de ferramentas que compõem a família ArcGis 10.x e o suporte aos programas; à Sulsoft, pela disponibilização do pacote Envi 5.x, para o processamento das imagens.

Referências

- ANTUNES, R.R.; BIAS, E. DE S.; BRITES, R.S.; DA COSTA, G.A.O.P. Desenvolvimento de técnica para monitoramento do cadastro urbano baseado na classificação orientada a objetos. Estudo de caso: município de Goianésia-Go. **Revista Brasileira de Cartografia**, v.67, p.357-372, 2015.
- ARVOR, D.; DURIEUX, L.; ANDRÉS, S.; LAPORTE, M.-A. Advances in geographic object-based image analysis with ontologies: a review of main contributions and limitations from a remote sensing perspective. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.82, p.125-137, 2013. DOI: 10.1016/j.isprsjprs.2013.05.003.
- BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: ANGEWANDTE GEOGRAPHISCHE INFORMATIONSVARBEITUNG, 12., 2000, Salzburg. [Anais]. Salzburg: Wichmann, 2000. p.12-23. Agit Symposium. Edited Josef Strobl, Thomas Blaschke, Gerald Griesebner
- BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS journal of photogrammetry and remote sensing**, v.65, p.2-16, 2010. DOI: 10.1016/j.isprsjprs.2009.06.004.
- BRANNSTROM, C.; JEPSON, W.; FILIPPI, A.M.; REDO, D.; XU, Z.; GANESH, S. Land change in the Brazilian Savanna (Cerrado), 1986-2002: comparative analysis and implications for land-use policy. **Land Use Policy**, v.25, p.579-595, 2008.
- BRASIL. Ministério do Meio Ambiente. **Catálogo de Imagens de Satélite Rapideye do Ministério do Meio Ambiente**. 2015.
- Disponível em: <<http://geocatalogo.mma.gov.br/>>. Acesso em: 11 nov. 2015.
- CAMARGO, F.F.; ALMEIDA, C.M.; COSTA, G.A.O.P.; FEITOSA, R.Q.; OLIVEIRA, D.A.B.; HEIPKE, C.; FERREIRA, R.S. An open source object-based framework to extract landform classes. **Expert Systems with Applications**, v.39, p.541-554, 2012. DOI: 10.1016/j.eswa.2011.07.044.
- CARVALHO JÚNIOR, O.A. de; RIBEIRO, M.N. da C.; MARTINS, E. de S.; GUIMARÃES, E.M.; MENESES, P.R.; GUIMARÃES, R.F. Análise de dados hiperespectrais em mina de manganês laterítico, São João da Aliança (GO). **Revista Brasileira de Geofísica**, v.25, p.199-212, 2007. DOI: 10.1590/S0102-261X2007000200008.
- CARVALHO, A.A.A.A. de; GREGÓRIO, L. da S.; FERREIRA, M.R.F.; COUTO, R. de S.; CASTRO, W.O. de; ALVES, W.F.; COSTA, G.O.A.P.; BRITES, R.S.; BIAS, E. de S. Análise de classificação de imagem Rapideye por meio dos softwares Interimage e Spring. In: CONGRESSO BRASILEIRO DE CARTOGRAFIA, 26.; CONGRESSO BRASILEIRO DE GEOPROCESSAMENTO, 5.; EXPOCART, 25., 2014, Gramado. **Mapas conectando o Brasil e a América do Sul**: anais. Rio de Janeiro: Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto, 2014.
- CONGALTON, R.G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. Boca Raton: CRC, 1999.137p.
- CRAWLEY, M.J. **The R Book**. Chichester: John Wiley & Sons, 2013. 975p.
- DEFRIES, R.S.; CHAN, J.C.-W. Multiple criteria for evaluating machine learning algorithms for land cover classification from satellite data. **Remote Sensing of Environment**, v.74, p.503-515, 2000. DOI: 10.1016/S0034-4257(00)00142-5.
- FERNANDES, R.R.; NUNES, G.M.; SILVA, T.S.F. Classificação orientada a objetos aplicada na caracterização da cobertura da terra no Araguaia. **Pesquisa Agropecuária Brasileira**, v.47, p.1251-1260, 2012. DOI: 10.1590/S0100-204X2012000900010.
- GREEN, A.A.; BERMAN, M.; SWITZER, P.; CRAIG, M.D. A transformation for ordering multispectral data in terms of image quality with implications for noise removal. **IEEE Transactions on Geoscience and Remote Sensing**, v.26, p.65-74, 1988. DOI: 10.1109/36.3001.
- HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The WEKA data mining software: an update. **ACM SIGKDD explorations newsletter**, v.11, p.10-18, 2009.
- HERMUCHE, P.M.; SANO, E.E. Identificação da Floresta Estacional Decidual no Vão do Paranã, Estado de Goiás, a partir da análise da reflectância acumulada de imagens do sensor ETM+/Landsat-7. **Revista Brasileira de Cartografia**, v.63, p.415-425, 2011.
- MANUAL técnico da vegetação brasileira: sistema fitogeográfico, inventário das formações florestais e campestres, técnicas e manejo de coleções botânicas, procedimentos para mapeamentos. Rio de Janeiro: IBGE, 2012. 274p. (IBGE. Manuais técnicos em geociências, 1).

- MARPU, P.R.; NEUBERT, M.; HEROLD, H.; NIEMEYER, I. Enhanced evaluation of image segmentation results. **Journal of Spatial Science**, v.55, p.55-68, 2010. DOI: 10.1080/14498596.2010.487850.
- NASCIMENTO, A.F.; RUBIM, I.B.; PEREIRA, E.G.S.; DE BARROS, R.S.; RICHTER, M. Classificação da cobertura da terra, utilizando os programas livres: InterImage, WEKA e QuantumGIS. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais**. São José dos Campos: Inpe, 2013. p.2258-2265. Editores José Carlos Neves e Lênio Soares Galvão.
- NASCIMENTO, E.R.P.; SANO, E.E. Identificação de cerrado rupestre por meio de imagens multitemporais do Landsat: proposta metodológica. **Sociedade e Natureza**, v.22, p.93-106, 2010.
- NOVACK, T.; KUX, H.; FEITOSA, R.Q.; COSTA, G.A.O.P. A knowledge-based, transferable approach for block-based urban land-use classification. **International Journal of Remote Sensing**, v.35, p.4739-4757, 2014. DOI: 10.1080/01431161.2014.921943.
- NUNES, J.F.; ROIG, H.L. Análise e mapeamento do uso e ocupação do solo da Bacia do Alto do Descoberto, DF/GO, por meio de classificação automática baseada em regras e lógica nebulosa. **Revista Árvore**, v.39, p.25-36, 2015. DOI: 10.1590/0100-67622015000100003.
- PASSO, D.P.; BIAS, E. de S.; BRITES, R.S.; COSTA, G.A.O.P. Uso do sistema InterIMAGE para a identificação de alvos urbanos em imagens do satélite Worldview II. **Revista Brasileira de Cartografia**, v.65/6, p.1211-1221, 2013.
- PINHEIRO, E. da S.; DURIGAN, G. Dinâmica espaço-temporal (1962-2006) das fitofisionomias em unidade de conservação do Cerrado no sudeste do Brasil. **Revista Brasileira de Botânica**, v.32, p.441-454, 2009. DOI: 10.1590/S0100-84042009000300005.
- PLANO de manejo: Parque Nacional das Emas. Brasília: Ibama, 2004. 893p.
- PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO. Laboratório de Visão Computacional. **InterImage 1.30**: Manual do usuário. 2012. Disponível em: <<http://www.lvc.ele.puc-rio.br/projects/interimage/pt-br/documentacao/>>. Acesso em: 12 nov. 2015.
- QUINLAN, J.R. **C4.5**: programs for machine learning. San Mateo: Morgan Kaufmann, 1993. 301p.
- R CORE TEAM. **R**: A language and Environment for statistical computing, Vienna: R Foundation for Statistical Computing, 2016.
- RIBEIRO, J.F.; WALTER, B.M.T. Fitofisionomias do bioma Cerrado. In: SANO, S.M.; ALMEIDA, S.P. de. **Cerrado**: ambiente e flora. Planaltina: EMBRAPA-CPAC, 1998. p.89-166.
- SANO, E.E.; ROSA, R.; BRITO, J.L.S.; FERREIRA, L.G. Land cover mapping of the tropical savanna region in Brazil. **Environmental Monitoring and Assessment**, v.166, p.113-124, 2010. DOI: 10.1007/s10661-009-0988-4.
- UNITED STATES. DEPARTMENT OF THE INTERIOR. United States Geological Service. **EarthExplorer**. Disponível em: <<http://earthexplorer.usgs.gov/>>. Acesso em: 14 jul. 2016.

Recebido em 20 de abril de 2016 e aprovado em 14 de julho de 2016