

Identificação de materiais urbanos por meio de métodos inovadores de classificação de imagens

Camila Souza dos Anjos^{1,2}
Cláudia Maria de Almeida¹
Lênio Soares Galvão¹

¹Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 – 12227-010 - São José dos Campos - SP, Brasil
{camilasa, almeida, lenio}@dsr.inpe.br

²Instituto de Estudos Avançados – IEAv, Força Aérea Brasileira - FAB
Caixa Postal 6044 – 12228-970 - São José dos Campos - SP, Brasil

Abstract. Urban areas represent one of the most challenging environments for remote sensing analysis. In general, urban areas represent spatially and spectrally complex environments, where exposed targets show profuse geometric and compositional variations. In this context, the use of images with high spatial and spectral resolutions is an excellent alternative for urban studies. The combination of these imagery characteristics allow a potential improvement for detection and discrimination of urban targets, especially using automatic classifiers. This research uses optical multispectral data with very high spatial resolution (VHR) acquired by the WorldView-2 satellite in eight spectral channels. The study area is a transect in the campus of the State University of Campinas (UNICAMP), located in the Campinas municipality, southeast of São Paulo State – Brazil. The area comprises a diversity of urban targets, such as French tiles, metal roofs, concrete/asphalt, water, low vegetation, woody vegetation, among others. The imagery dataset were processed by means of nonparametric classifiers. Three classification experiments were performed using the following techniques: (i) Decision Tree, Support Vector Machines (SVM), and (ii) Random Forest (RF). A comparative evaluation among these three nonparametric classification methods was also produced, seeking to examine the confusion matrix and the *Kappa* index. The results indicated that all classifiers showed high performance with *Kappa* values greater than 0.8. The SVM got the best *Kappa* result (0.93).

Palavras-chave: Data Mining, Decision Tree, Random Forest, SVM (Support Vector Machine), Mineração de Dados, Árvore de Decisão, Floresta Randômica, SVM (Máquina de Vetores de Suporte).

1. Introdução

A evolução dos níveis de resolução espacial e espectral em dados de sensoriamento remoto orbital tem ampliado a capacidade de discriminação dos alvos. Tal enriquecimento tem proporcionado a devida separação entre materiais de similar aparência, além de tornar possível a identificação de objetos relativamente pequenos no ambiente urbano. Para Herold et al. (2003), ambientes urbanos representam uma das mais desafiadoras áreas de análise de sensoriamento remoto. Isto ocorre devido à alta diversidade espacial e espectral de materiais de superfície urbana, que incluem uma ampla gama de telhados, estradas, calçadas de diversas idades, qualidades e composição. Essa diversidade espectral cria um ambiente particularmente desafiador para mapeamento.

Segundo Weber e O'Connell (2011), em certas aplicações, como, por exemplo, o mapeamento de áreas urbanas, a integração de alta resolução espacial e espectral é obrigatória para atingir um mapeamento suficientemente preciso com bons resultados na detecção de alvos. Assim, o ideal para aplicações urbanas é de fato o uso de imagens que consigam ter tanto uma alta resolução espacial, quanto uma alta resolução espectral, o que representa um significativo avanço na análise urbana por meio de sensoriamento remoto. A combinação dessas duas características pode permitir uma melhor detecção dos elementos que compõem o espaço urbano, sobretudo com o auxílio de classificadores automáticos de última geração.

Fazendo uma apreciação geral sobre os sensores orbitais em operação com alta resolução espacial, percebe-se que a maioria deles é limitada em relação à resolução espectral, apresentando geralmente quatro bandas multiespectrais (Azul, Verde, Vermelho e Infravermelho Próximo) e uma banda pancromática com melhor resolução espacial que as demais. Na data de início desta pesquisa, destacava-se o sensor orbital WorldView-2 (WV-2), lançado em 2009, que representava um avanço por possuir, além das quatro bandas tradicionais já citadas, outras quatro novas bandas espectrais (Azul Costeiro, Amarelo, Vermelho Limítrofe e Infravermelho Próximo-2). Atualmente, já está em operação o WorldView-3 que, além dos mesmos canais espectrais com melhor resolução espacial que o WorldView-2, possui também outras oito bandas na região do SWIR (*Short Wave InfraRed*) e doze bandas voltadas para o estudo da atmosfera.

Infelizmente, todo o avanço presente ou futuro da tecnologia do sensoriamento remoto não resolve por inteiro os problemas do mapeamento urbano. Apesar desses satélites terem resoluções espaciais típicas de sensores aéreos, uma grande proporção de pixels da imagem ainda será uma mistura de tipos de cobertura fundamentais (Griffiths et al., 2010). O problema da heterogeneidade espacial e espectral é agravado em áreas suburbanas, onde a cobertura do solo é frequentemente uma “colcha de retalhos”, o que justifica a necessidade do estudo e avaliação de métodos inovadores para a classificação de áreas urbanas e periurbanas.

De acordo com Cortijo e La Blanca (1997), os classificadores espectrais são divididos em duas categorias principais: classificadores paramétricos e não-paramétricos. Os classificadores paramétricos assumem a existência de uma distribuição de probabilidades fundamental entre os dados. Os classificadores não-paramétricos nos levam para além da noção de distribuições de probabilidade contínuas e métricas, em direção a problemas discretos, que são resolvidos por métodos de reconhecimento de padrões baseados em regras ou sintática (Duda et al., 2012).

Assim, o presente trabalho visa explorar diferentes métodos não-paramétricos que correspondem ao estado da arte em classificação de imagens, aplicando-os a uma cena urbana do sensor WV-2. O objetivo é comparar o desempenho de três classificadores (Árvore de Decisão, Floresta Randômica e Máquina de Vetores de Suporte), procurando identificar aquele de melhor desempenho para o conjunto de dados em análise.

2. Metodologia de Trabalho

O sensor orbital WV-2, possui uma banda pancromática e oito bandas multiespectrais que apresentam 0,46 m e 1,84 m de resolução espacial ao nadir, respectivamente. Tais imagens são quantizadas em 11 bits de resolução radiométrica, com o seguinte posicionamento de bandas: Azul Costeiro (400-450 nm), Azul (450-510 nm), Verde (510-580 nm), Amarelo (585-625 nm), Vermelho (630-690 nm), Vermelho Limítrofe (705-745 nm), Infravermelho Próximo 1 (705-745 nm) e Infravermelho Próximo 2 (860-1040 nm). A cena WV-2 utilizada no presente trabalho (Figura 1) foi adquirida em 02 de julho de 2010, com apontamento de 6,75° e 0% de cobertura de nuvem. A área de interesse imageada é parte do campus da UNICAMP (Universidade Estadual de Campinas), localizada no município de Campinas, no estado de São Paulo, Brasil.

Para a realização de um trabalho de identificação de materiais por meio de dados de sensoriamento remoto, é essencial a transformação dos ND (Números Digitais) da imagem em grandezas radiométricas como radiância ou reflectância. Assim, o primeiro passo foi o pré-processamento da imagem, com transformação dos NDs em radiância utilizando o *software* ENVI 4.7. A correção atmosférica e transformação da imagem para reflectância de superfície foi feita em seguida por meio do modelo FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*), implementado no mesmo aplicativo. Tal procedimento possui soma

importância, visto que a atmosfera presente entre a superfície da Terra e o sensor é composta por diferentes gases e partículas em suspensão, que afetam a qualidade da imagem.

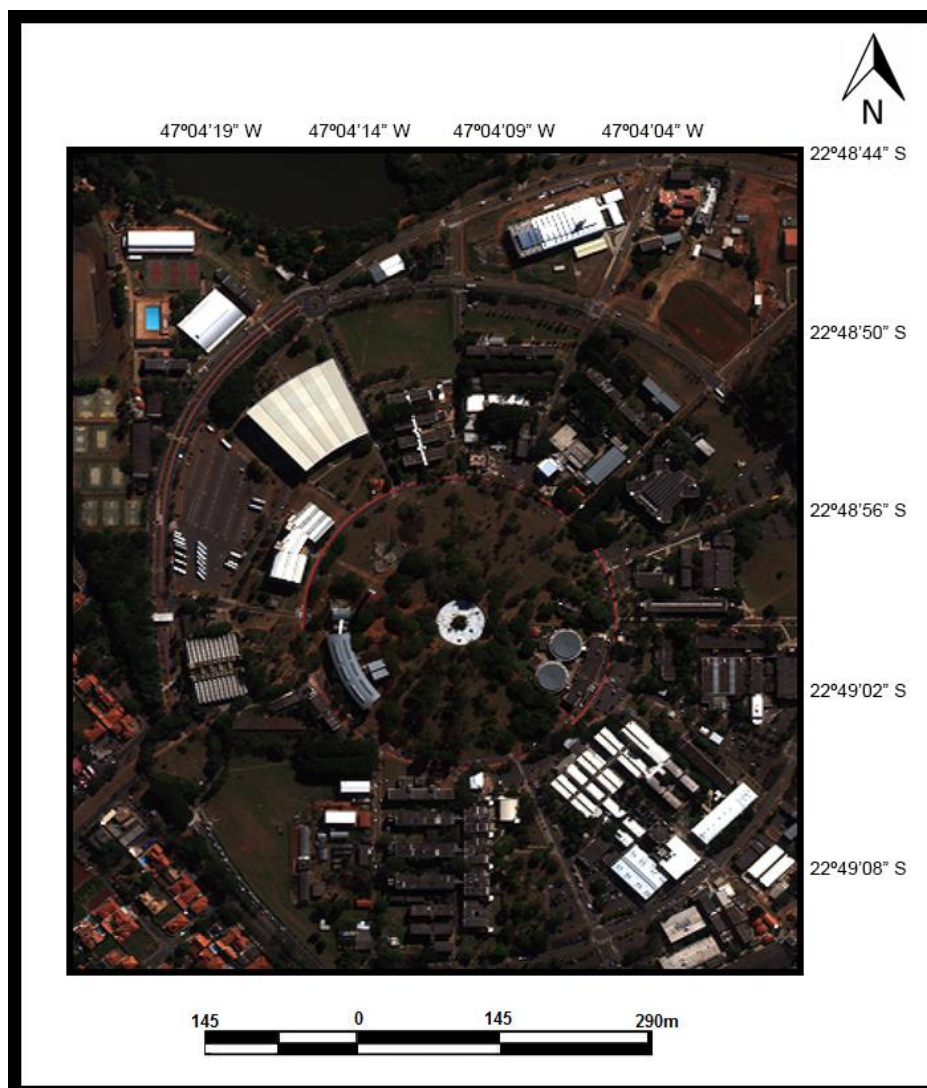


Figura 1 – Cena WorldView-2 de 02/07/2010 na composição colorida 5R3G2B, do campus da UNICAMP.

Com o objetivo de extrair importantes informações dos dados e melhorar o conjunto de atributos a ser inserido no minerador de dados, foram gerados os atributos PC (Componentes Principais) e NDVI (Índice de Vegetação por Diferença Normalizada) usando o *software* ERDAS Imagine 2013. A análise por Componentes Principais (ACP) tem por objetivo gerar, a partir de combinações lineares das bandas originais correlacionadas, um novo conjunto de bandas descorrelacionadas. De acordo com Jolliffe (2005), a ACP é uma técnica utilizada para reduzir a dimensionalidade dos dados, substituindo as variáveis originais por um número menor de variáveis transformadas (CPs). Proposto por Rouse et al. (1973), o NDVI (*Normalized Difference Vegetation Index*) é o índice de vegetação mais frequentemente utilizado, sendo calculado a partir das bandas do vermelho (V) e infravermelho próximo (IVP) (Equação 1):

$$NDVI = \frac{IVP - V}{IVP + V} \quad (1)$$

O passo seguinte foi a segmentação multirresolução realizada no Ecognition Developer 9. De acordo com Matsuoka e Haertel (2007), a segmentação multirresolução é essencialmente um procedimento de otimização heurística, que minimiza localmente a média da heterogeneidade dos objetos da imagem para uma dada resolução sobre a cena inteira. De forma mais simples é possível compreender que a abordagem multirresolução consiste em analisar os objetos da imagem em diferentes níveis de resolução. É fundamentada no fato de que objetos pequenos podem ser adequadamente analisados em uma resolução mais fina, enquanto que objetos maiores podem ser apropriadamente manipulados em uma resolução mais grosseira. A segmentação pode ser realizada em múltiplas resoluções, pela variação de parâmetros do algoritmo de segmentação, que altera o nível de resolução do processamento (Leonardi, 2010).

Ainda no Ecognition Developer 9, foram coletadas amostras para as 18 classes de materiais urbanos detectados na cena: Asfalto, Concreto, Piscina, Pedra Mineira, Saibro, Quadras Esportivas, Pista de Atletismo, Cobertura Metálica 1, Cobertura Metálica 2, Cobertura Metálica 3, Cobertura de Fibrocimento, Telha Francesa, Vegetação Arbórea, Vegetação Rasteira, Lago Artificial, Solo Exposto, Ciclovia e Sombra.

Para cada conjunto de amostras em cada uma das classes foram criados os seguintes atributos: média para cada uma das bandas do WV-2, média para cada componente principal, média do NDVI, desvio padrão para cada uma das bandas WV-2, desvio padrão para cada uma das componentes principais, desvio padrão para o NDVI, além dos atributos de brilho e máxima diferença, totalizando assim 42 atributos. Todos esses parâmetros foram exportados do Ecognition Developer 9 em um arquivo de formato .csv, o qual, após sofrer uma edição no Excel 2013, foi importado pelo WEKA (*Waikato Environment for Knowledge Analysis*) na versão 3.6.10, em que foi realizada a mineração e a classificação dos dados.

Atualmente, uma vasta quantidade de dados está à disposição da comunidade. Descobrir o conhecimento ou a verdadeira informação de interesse dentro de um vasto conjunto de dados é o desafio da Mineração de Dados, ferramenta que contribui para a redução da dimensionalidade de dados. Han et al. (2012) definem Mineração de Dados como o processo de descoberta de padrões interessantes e conhecimento a partir de grandes quantidades de dados. Com o objetivo de reduzir a alta correlação entre as bandas e o custo computacional, Li et al. (2011) propõem procurar a melhor combinação de bandas para a classificação do uso do solo. Já na identificação de alvos urbanos, Herold et al. (2004) selecionam bandas com melhor separabilidade espectral para os alvos selecionados, baseando-se no comportamento espectral dos mesmos. Segundo Han et al. (2012), a seleção de atributos, o que aqui é chamado de mineração de dados, reduz o tamanho do conjunto de dados, removendo atributos irrelevantes ou redundantes por meio de testes de significância estatística, assumindo que os atributos são independentes uns dos outros.

Foram testados três classificadores não-paramétricos (Árvore de Decisão C4.5, Floresta Randômica e SVM) usando o aplicativo WEKA 3.6.10. O algoritmo C4.5 gera um classificador em forma de uma árvore de decisão, cuja estrutura possui folhas que indicam as classes e nós que especificam um teste a ser realizado em um dos atributos, formando um ramo (ou sub-árvore) para cada resultado possível do teste. Segundo Han et al. (2012), os algoritmos de árvores de decisão foram originalmente planejados para classificação, nos quais uma árvore de decisão é construída em uma estrutura de fluxograma (diagrama de fluxo). Assim, o resultado do classificador é obtido utilizando uma sequência de decisões, em que um conjunto de regras é implementado e estas determinam o caminho a ser seguido, começando do nó-raiz e finalizando no nó-terminal (ou folha), que representa a classe para qual o objeto foi classificado (Tso e Mather, 2009).

A técnica de classificação introduzida por Breiman (2001), chamada Floresta Randômica (Random Forest), utiliza um conjunto de árvores de decisão e vetores aleatórios

independentes. Com as amostras de treinamento originais, as buscas são realizadas através de um subconjunto que seleciona as variáveis de entrada aleatoriamente para determinar uma divisão (para cada nó). À medida que cada árvore utiliza apenas uma parte das variáveis de entrada, o algoritmo é consideravelmente mais leve do que os classificadores que comparam árvores de decisão de maneira convencional. A medida de proximidade entre duas amostras é obtida por meio da contagem de quantas árvores acabam no mesmo nó terminal, e a saída do classificador é determinada pela maioria dos votos das árvores (Gislason et al., 2006). A técnica foi aplicada nesse trabalho com um total de 10 árvores.

De acordo com Mercier e Lennon (2003), a técnica SVM consiste em encontrar a superfície de separação ótima entre as classes, graças à identificação de amostras representativas. Essas amostras são chamadas de vetores de suporte. Se o conjunto de dados de treinamento não é linearmente separável, um método de semente é utilizado para simular uma projeção não-linear dos dados em um espaço de dimensão superior, onde as classes são linearmente separáveis. Além disso, mesmo trabalhando com um pequeno número de amostras de treinamento, elas são suficientes para encontrar os vetores de suporte. Para Tso e Mather (2009), o classificador SVM representa um grupo teoricamente superior dentro dos algoritmos de aprendizado de máquina. O que atrai no SVM é a sua capacidade de minimizar erros ao resolver o problema de classificação. A classificação por SVM é considerada o estado da arte quando se trata de algoritmos de aprendizado de máquina (Xiong et al., 2010).

Após a classificação do conjunto de dados pelos três métodos citados, métricas de avaliação da qualidade das classificações foram aplicadas também no WEKA 3.6.10. Segundo Fidalgo (1995), a forma mais utilizada para representar a exatidão da classificação é a comparação da classificação derivada da imagem com a referência a partir da utilização de uma matriz de erro (matriz de confusão). Tal matriz pode ser utilizada como base para uma série de técnicas descritivas e analíticas para estimar a exatidão da classificação. Congalton (1983) sugere a utilização do índice *Kappa*, proposto por Cohen (1960). A maioria dos trabalhos acadêmicos tem utilizado o índice *Kappa* para avaliar a qualidade da classificação de imagens. Entretanto, tal índice é questionado por Pontius Jr. e Millones (2011) na publicação intitulada “Morte ao *Kappa*” (*Death to Kappa*), na qual apresentam diversas razões para abandonar o uso do índice, afirmando que o índice *Kappa* tradicional e todas as suas variações são inúteis, falhos e enganosos. Os autores recomendam para fins de comparação entre mapas e avaliação da precisão da classificação, substituir o *Kappa* por uma abordagem mais simples e útil que resume a matriz de confusão em dois componentes de discordância em termos de quantidade e distribuição espacial das classes. Dessa forma, o presente trabalho não apresentará como métrica de avaliação da qualidade apenas o índice *Kappa*, mas o apresentará em conjunto com as informações de Instâncias Corretamente Classificadas, Instâncias Incorretamente Classificadas, Erro Médio Absoluto e Erro Médio Quadrático.

3. Resultados e Discussão

As principais métricas de avaliação das três classificações realizadas são apresentadas na Tabela 1. O WEKA não apresenta como resultado a imagem classificada, mas apenas as informações tabulares do processamento, como o modelo de classificação, as informações do método, a matriz de confusão e outras métricas de avaliação da qualidade além da acurácia resultante de cada classe.

Os métodos SVM e Random Forest rodam em um tipo de “*black box*”, o que torna impossível a reprodução do seu resultado de classificação por outro *software* do mercado. De forma diversa, o algoritmo C4.5 tem como dado de saída, além dos anteriormente citados, a própria árvore de decisão, o que torna possível a reprodução da classificação em um outro aplicativo. Dessa forma, a árvore gerada pelo WEKA (Figura 2) foi implementada na forma

de rede semântica no Ecognition Developer 9, gerando a imagem classificada apresentada na Figura 3. Dentre os 42 atributos inseridos no WEKA3.6.10, o minerador de dados utilizou apenas seis deles para gerar a árvore de decisão: a reflectância das bandas WV-2 do azul, verde e amarelo (B2, B3, B4), as Componentes Principais (CP5 e CP7), além do atributo de Máxima Diferença.

Tabela 1. Métricas de Avaliação da Qualidade das Classificações.

	SVM	Random Forest	C4.5
Instâncias Corretamente Classificadas	93,5484 %	88,8563%	81,5249%
Instâncias Incorretamente Classificadas	6,4516 %	11,1437%	18,4751%
Erro Médio Absoluto	0,0989	0,0739	0,0252
Erro Médio Quadrático	0,2179	0,1677	0,1322
Índice <i>Kappa</i>	0,9314	0,8816	0,8034

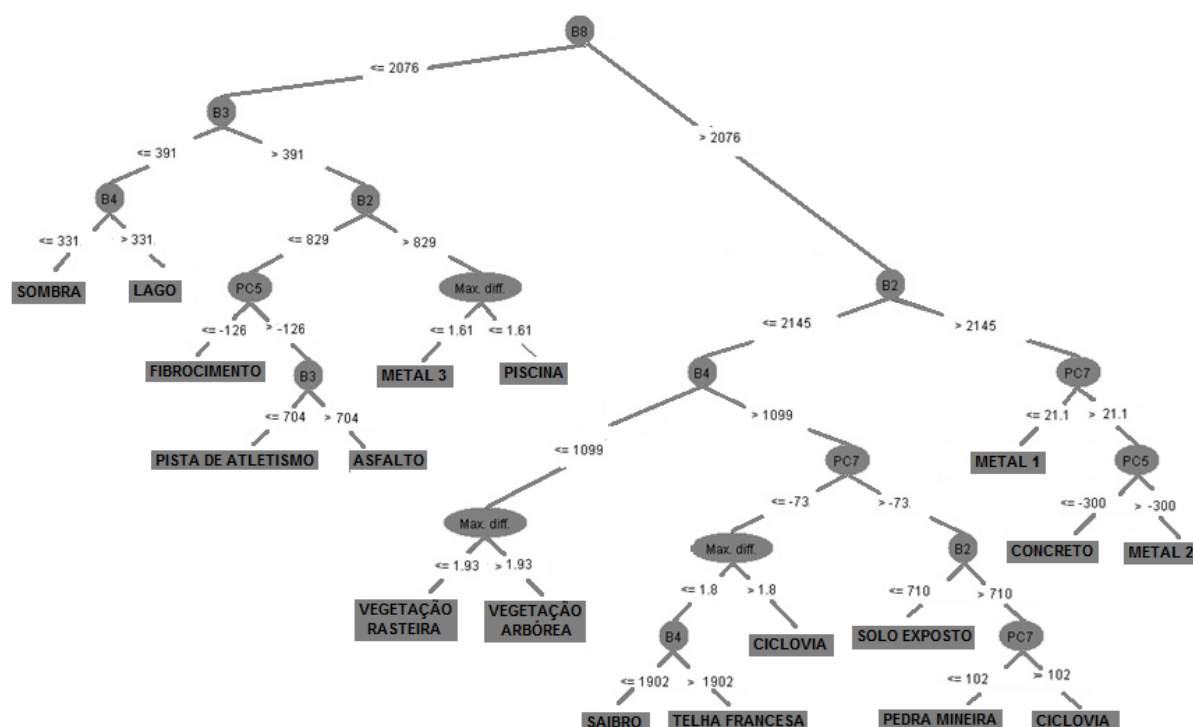


Figura 2. Árvore de Decisão gerada pelo algoritmo C4.5 no software WEKA 3.6.10.

Em conjunto com os bons resultados numéricos apresentados, a classificação da árvore de decisão apresentou um resultado visual muito bom. Observou-se a presença de pequenos erros de classificação, por meio de algumas confusões já esperadas na separação de classes, como telha francesa e saibro, asfalto e concreto, lago artificial e sombra, entre outros.

4. Conclusões

Os três métodos de classificação apresentaram mais de 80% de instâncias corretamente classificadas. O método C4.5 apresentou o menor valor de instâncias corretamente classificadas. Entretanto, dentre os métodos testados no WEKA 3.6.10, este foi o único reproduzido em outra plataforma. Tal reprodução no Ecognition Developer 9 gerou uma classificação de ótimo aspecto visual.

Os métodos Floresta Randômica e SVM, apesar de apresentarem melhores resultados na avaliação da qualidade da classificação, sendo que o SVM chegou a apresentar 93.5% de instâncias corretamente classificadas, não geraram resultados capazes de serem reproduzidos e assim serem analisados visualmente. Uma alternativa exclusiva para o método SVM seria exportar as amostras em um formato legível pelo ENVI 4.7 e gerar a classificação, visto que o *software* possui tal ferramenta.

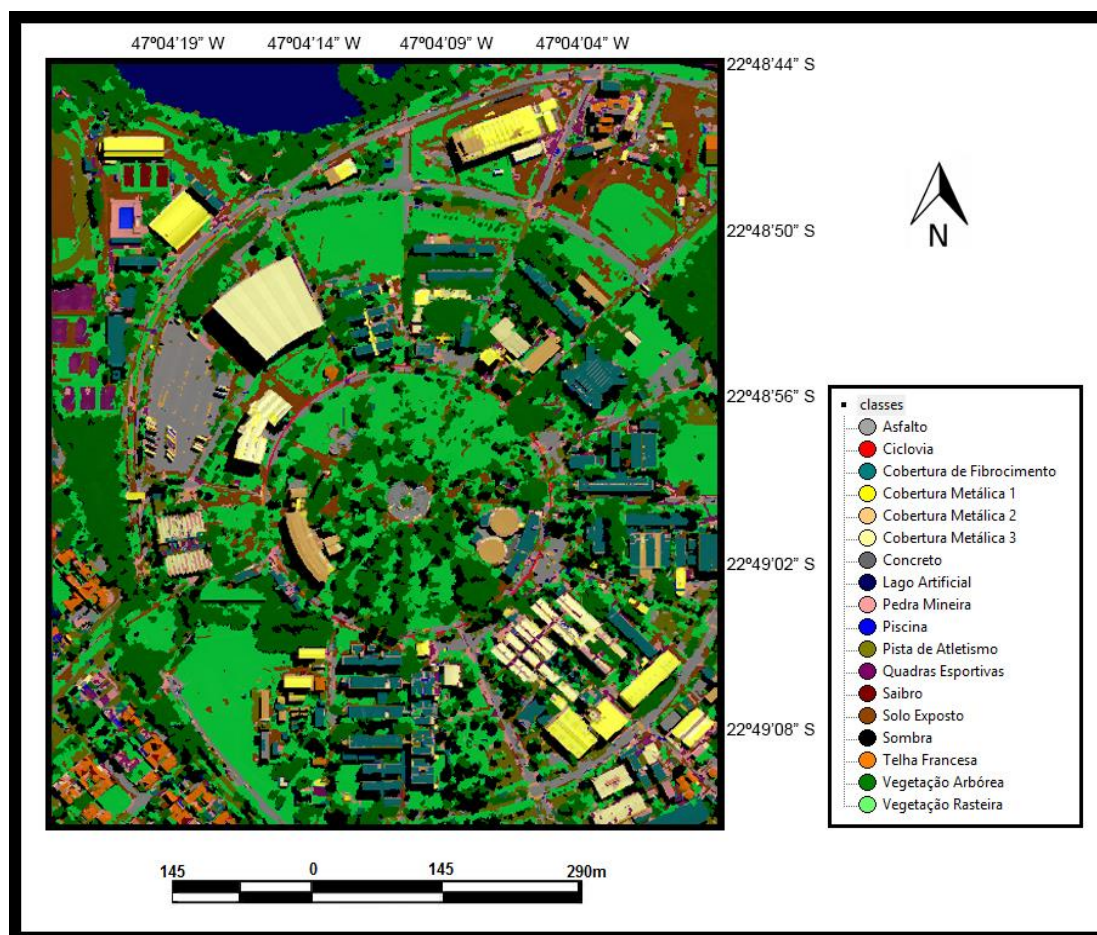


Figura 3. Imagem classificada no Ecognition Developer 9 pela implementação hierárquica da árvore de decisão gerada pelo C4.5.

Referências Bibliográficas

Breiman, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001.

Cohen, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 20, n. 1, p. 37-46, 1960.

Congalton, R. G. Assessing Landsat classification accuracy using discrete multivariate analysis statistical techniques. **Photogrammetric Engineering and Remote Sensing**, v. 49, n. 12, p. 1671-1678, 1983.

Cortijo, F. J.; La Blanca, N. P. A comparative study of some non-parametric spectral classifiers. Applications to problems with high-overlapping training sets. **International Journal of Remote Sensing**, v.18, n.6, p.1259-1275, 1997.

Duda, R. O.; Hart, P. E.; Stork, D. G. **Pattern Classification**. New Delhi: John Wiley & Sons, 2012. 654 p. ISBN(978-81-265-1116-7).

Fidalgo, E. C. C. **Exatidão no processo de mapeamento temático da vegetação de uma área de mata atlântica no estado de São Paulo, a partir de imagens TM-LANSAT**. 1995. 167p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1995.

Gislason, O.; Benediktsson, J. A.; Sveinsson, J. R. Random Forests for land cover classification. **Pattern Recognition Letters**, v. 27, n. 4, p. 294-300, 2006.

Griffiths, P.; Hostert, P.; Gruebner, O.; Van Der Linden, S. Mapping megacity growth with multi-sensor data. **Remote Sensing of Environment**, v. 114, p. 426-439, 2010.

Han, J.; Kamber, M.; Pei, J. **Data mining: concepts and techniques**. Whaltan: Elsevier, 2012. 744p. 3 ed. ISBN(978-0-12-381479-1).

Herold, M.; Gardner, E.M.; Roberts, D.A. Spectral resolution requirements for mapping urban areas. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, p. 1907-1919, 2003.

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.

Jolliffe, I. Principal Component Analysis. In: Everitt, B. S.; Howell, D. (Org). **Encyclopedia of Statistics in Behavioral Science**. John Wiley & Sons, 2005. 2352p. ISBN: 978-0-470-86080-9

Leonardi, F. **Abordagens cognitivas e mineração de dados aplicadas a dados ópticos orbitais e de laser para a classificação de cobertura do solo urbano**. 2010. 162 p. (sid.inpe.br/mtc- m19@80/2010/03.17.11.42-TDI). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010. Disponível em: <<http://urlib.net/8JMKD3MGP7W/376H8M2>>. Acesso em: 28 ago. 2014.

Li, S.; Wu, H.; Wan, D.; Zhu, J. An effective feature selection method for hyperspectral image classification based on genetic algorithm and support vector machine, **Knowledge-Based Systems**, v. 24, p. 40-48, 2011.

Matsuoka, J. V.; Haertel, V. F. A. Investigação do processo de segmentação multiresolução utilizando o critério de ponderação de formas e cores aplicadas às imagens de áreas urbanas de alta resolução espacial do satélite Ikonos. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 13., 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007. Artigos, p. 589-596. CD-ROM, On-line. ISBN 978-85-17-00031-7. Disponível em: <<http://urlib.net/dpi.inpe.br/sbsr@80/2006/11.15.11.19>>. Acesso em: 28 ago. 2014.

Mercier, G.; Lennon, M. Support vector machines for hyperspectral image classification with spectral-based kernels, In: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'03), 2003, Melbourne, Australia. **Proceedings...** Melbourne: IEEE International, 2003. p. 288-290.

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.

Rouse, J. W., R. H. Haas, J. A. Schell, and D. W. Deering (1973). Monitoring vegetation systems in the Great Plains with ERTS. In: Third ERTS Symposium, 1973. **Proceedings...** Greenbelt: NASA SP-351, 1973. Papers, p. 309-317. Disponível em: <http://www.researchgate.net/publication/246866091_Monitoring_vegetation_systems_in_the_Great_Plains_with_ERTS>. Acesso em: 05 nov. 2014.

Tso, B.; Mather, P. **Classification Methods for Remotely Sensed Data**. Boca Raton: Taylor & Francis, 2009. 2ed. 356 p. ISBN(978-1-4200-9072-7).

Weber, R.A.; O'Connell, K.M. **Alternative Futures: United States Commercial Satellite Imagery in 2020**. Washington: Innovative analytics & training, 2011. 111 p. Disponível em: <<http://www2.gwu.edu/~nsarchiv/NSAEBB/NSAEBB404/docs/37.pdf>> Acesso em: 29 set. 2014.

Xiong, Y.; Zhang, Z; Chen, F. Comparison of artificial neural network and support vector machine methods for urban land use/cover classifications from remote sensing images A Case Study of Guangzhou, South China. **Computer Application and System Modeling**, v.13, p. 52- 56, 2010.