

## **Deteção de queimadas no Pantanal a partir de classificação orientada a objeto e informações multiespectrais de sensoriamento remoto**

Daniel Capella Zanotta <sup>1</sup>

Tessio Novak <sup>1</sup>

Samuel Martins da Costa Coura <sup>1</sup>

Hiran Zani <sup>1</sup>

Cláudia Maria Almeida <sup>1</sup>

<sup>1</sup> Instituto Nacional de Pesquisas Espaciais - INPE  
Av. dos Astronautas, 1.758 Jd. Granja - CEP: 12227-010  
São José dos Campos, SP, Brasil  
{zanotta, tessio, samuel, hzani, almeida}@dsr.inpe.br

**Resumo.** Este estudo apresenta aplicação da técnica de classificação orientada a objeto para o mapeamento de áreas de queimadas e outras classes que compõem a paisagem do Pantanal. A técnica de classificação orientada a objeto representa o conhecimento humano através de relações semântico-hierárquicas entre as classes, explorando atributos espectrais, texturais, geométricos e topológicos dos alvos de uma imagem orbital. A área de teste está localizada no norte do Pantanal. Sua escolha justifica-se pela ocorrência de alvos representativos de todo o bioma Pantanal. Pré-processamentos de calibração radiométrica e correção atmosférica foram aplicados à cena Landsat-5 TM utilizada neste trabalho. Para a segmentação, usou-se a rotina implementada no aplicativo Definiens. Posteriormente, realizou-se a etapa de treinamento com amostras das classes escolhidas. Três classificadores foram utilizados: (1) árvore de decisão (algoritmo C4.5); (2) vizinho-mais-próximo; e (3) uma abordagem mista combinando estes dois classificadores em uma rede hierárquica de classes. A análise de acurácia mostrou que o algoritmo vizinho-mais-próximo produziu o resultado mais preciso (94% de exatidão global e índice *Kappa* de 0,92), seguido pelas abordagens de árvore de decisão (83% de exatidão global e índice *Kappa* de 0,78) e mista (68% de exatidão global e índice *Kappa* de 0,61). Estes resultados sugerem que a técnica de classificação orientada a objeto pode produzir mapas de alta confiabilidade para o Pantanal. Com relação às queimadas, o método se mostrou eficiente para extrair com precisão os limites desta classe e pode ser utilizado para monitoramento e quantificação das áreas afetadas.

**Palavras-chave:** classificação orientada a objeto, árvore de decisão, classificador por vizinho-mais-próximo, queimadas, Pantanal, sensoriamento remoto

**Abstract.** This study presents an object-based classification approach to map burned areas and other land cover classes in an area in the Pantanal (Wetlands) biome. This approach emulates the human expert knowledge can be represented through a semantic and hierarchical class network as well as through the use of spectral, textural, geometric, and topological features in the identification of the classes of interest. The choice of this scene is justified by the occurrence of features representative of the whole Pantanal biome. Digital image pre-processing procedures such as radiometric calibration and atmospheric correction were applied in the Landsat-5 TM scene used in this research. The *Multiresolution Segmentation* tool available in the Definiens Developer system was used for the generation of representative image objects. Training samples of the classes of interest were collected. Three different classification algorithms were then applied: (1) the C4.5 decision tree algorithm, (2) the nearest-neighbor classifier, and (3) a mixed approach combining both algorithms and a hierarchical net. The accuracy analysis showed that the nearest-neighbor classifier achieved the best results (Kappa index of 0.92) followed by the decision tree algorithm (Kappa index of 0.78) and the mixed approach (Kappa index of 0.61). The results suggest that the object-based classification approach can be used to generate valuable and precise maps of burned areas in the Pantanal biome. As our classifications have precisely extracted the edges/borders of the burned scars and the respective size of the affected areas, these data may be used as an input to climate change-related studies designed to model climatic processes occurring in the region.

**Key-words:** object-based classification, decision trees, nearest-neighbor classifier, burnt areas, Pantanal, remote sensing

## 1. Introdução

Queimadas são consideradas parte integrante de muitos ecossistemas. No entanto, a queima de biomassa afeta diretamente o ciclo do carbono, pois perturba a química atmosférica global através da liberação de aerossóis e gases causadores do efeito estufa (Gitas et al. 2004). Segundo Lashof (1996), o principal gás do efeito estufa é o dióxido de carbono ( $\text{CO}_2$ ). Durante uma queimada, esse gás compõe aproximadamente 90% das emissões de gases liberados para a atmosfera (Levine et al. 1996). Esta liberação de carbono para a atmosfera causa um impacto direto nas trocas radiativas na superfície, podendo influenciar mudanças no clima global. Segundo Grace (2004), cerca de 60% do aquecimento global é atribuído à elevação da concentração de dióxido de carbono na atmosfera. Quando uma região é atingida pelo fogo, informações detalhadas e atualizadas sobre a localização e a extensão da área queimada são importantes na avaliação das perdas econômicas e efeitos ecológicos, no monitoramento do uso e cobertura da terra, assim como para a quantificação dos impactos e modelagem atmosférica e climática da queima de biomassa (Caetano et al. 1994; Pereira et al. 1997).

Técnicas de monitoramento eficientes são necessárias para investigar o cenário ecológico após o impacto do fogo. Diversos estudos têm investigado a capacidade do sensoriamento remoto para produzir estimativas precisas sobre as áreas queimadas. Para o Pantanal, recentemente dois estudos foram realizados utilizando técnicas semi-automáticas (Gonçalves et al. 2006; Zanotta 2009). De acordo com Chuvieco (1999), dados de sensoriamento remoto podem contribuir para uma melhor relação custo-método gerando economia de tempo ao caracterizar a intensidade e a extensão de áreas queimadas. Por conseguinte, o desenvolvimento de metodologias capazes de produzir automaticamente mapas mais precisos em escalas local, regional e global tem sido investigado por diversos trabalhos (Justice et al. 1993). A classificação orientada a objeto, que opera com segmentos ao invés de pixels, permite a integração de um amplo espectro de informações presentes na cena, tais como valores espectrais, forma, textura, entre outros. Essa técnica de classificação pode ser realizada utilizando não só os atributos individuais do objeto, mas também relações topológicas existentes entre os alvos. Uma razão para a

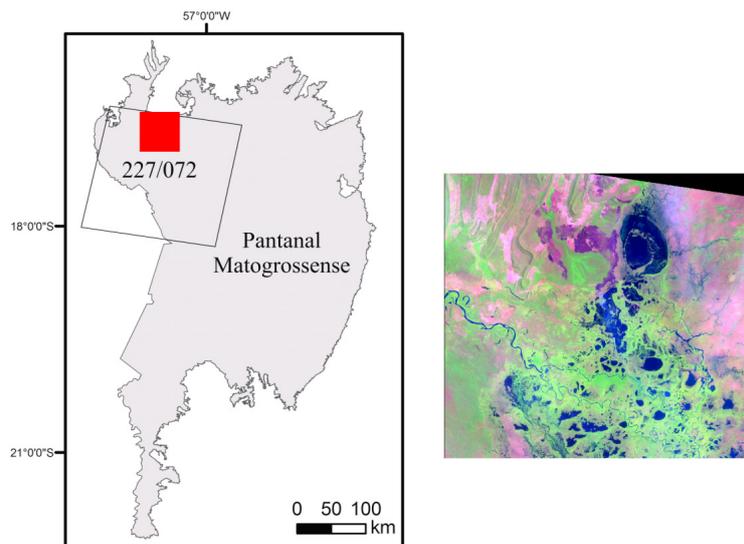
abordagem orientada a objeto é o fato de que, em muitos casos, o resultado esperado na maioria das análises é a extração de objetos que tenham significado no mundo real. Essa tarefa não pode ser cumprida pelos classificadores tradicionais, cujas abordagens limitam-se a um reduzido número de atributos exclusivamente estatísticos (Baatz e Schäpe 1999).

## 2. Objetivo

O objetivo deste trabalho é aplicar um método de classificação orientada a objeto em uma área teste do Pantanal, contendo queimadas entre outras classes de cobertura da terra características da região. Ao invés de classificar a imagem com base nos valores dos pixels, sugere-se que a imagem seja segmentada e que a classificação seja orientada a objetos resultantes do processo de segmentação, obedecendo a regras previamente estabelecidas.

## 3. Material e Métodos

A área de estudo selecionada para testar a abordagem sugerida se situa ao norte do Pantanal (**Figura 1**). A imagem utilizada é do satélite *Landsat 5* sensor *TM* (órbita/ponto 227/072) do dia 05/10/2002 e foi adquirida imediatamente após uma queimada. A escolha da área levou em conta o número de classes presentes na cena, a qual representa adequadamente boa parte da diversidade encontrada na região. Dentre elas, podemos citar vegetação densa (ripária) vegetação rala (cerrado), solo exposto, queimadas e corpos d'água. As imagens possuem sete bandas espectrais: banda 1, que cobre a faixa espectral do azul (0.45 a 0.52  $\mu\text{m}$ ); banda 2 na faixa do verde (0.50 a 0.60  $\mu\text{m}$ ); banda 3 na faixa do vermelho (0.63 a 0.69  $\mu\text{m}$ ); banda 4 na faixa do infravermelho próximo (0.76 a 0.90  $\mu\text{m}$ ); banda 5 no infravermelho médio (1.55 a 1.75  $\mu\text{m}$ ); banda 6 no infravermelho termal (10.4 a 12.5  $\mu\text{m}$ ); e banda 7 no infravermelho médio (2.08 a 2.35  $\mu\text{m}$ ). As cenas foram fornecidas pelo *U.S. Geological Survey* e possuem o nível de correção L1T, que incorpora correções radiométricas e georreferenciamento com exatidão de 0,8 pixel (USGS 2010). Os pré-processamentos realizados consistiram na calibração radiométrica, com valores de ganho e *offset* atualizados de acordo com Chander et al. (2009) e conversão dos números digitais para reflectância aparente de superfície. Posteriormente, foi aplicado o método de correção atmosférica de subtração do pixel escuro, descrito por Chavez (1988).



**Figura 1.** Recorte da cena *TM-Landsat 5* (órbita/ponto 227/072) selecionada para o estudo, representada através da composição 5(R) 4(G) 3(B).

O *software* utilizado para o processo de montagem da rede hierárquica de segmentação e classificação foi o Definiens Developer (Definiens 2009).

O procedimento de segmentação foi realizado utilizando-se o algoritmo de crescimento de regiões proposto por Baatz e Schäpe (2000). Os parâmetros usados são: forma: 0,1; cor: 0,9; compacidade: 0,5; suavidade: 0,5, e o parâmetro de escala foi fixado em 10. As bandas 3, 4 e 5 foram usadas no processo de segmentação. Todo o processo de parametrização, o qual gerou segmentos mais coerentes em termos de preservação das bordas entre os objetos, foi realizado de modo heurístico.

Uma vez realizado o procedimento de segmentação da imagem, deu-se início ao processo de coleta de amostras. A coleta das amostras de cada classe para treinamento e teste dos classificadores foi feita através da seleção manual de segmentos diretamente sobre a imagem disponível. Optou-se por coletar apenas quarenta amostras por classe. O intuito foi avaliar a eficácia das abordagens de classificação empregadas com um número baixo de amostras, o que resulta em um baixo tempo de produção da informação, que é essencial do ponto de vista da operacionalidade do processo de reconhecimento. Dois grupos distintos e independentes de amostras foram coletados: um para o treinamento dos classificadores e outro para a avaliação das classificações geradas.

Os classificadores por Árvore de Decisão (AD) (Quinlan 1993) e por Vizinheiro Mais Próximo (VMP) foram usados em três estratégias de classificação: (1) classificação por VMP, (2) classificação por AD e (3) abordagem mista (VMP e AD) de classificação.

Classificadores por VMP atribuem um elemento de análise (pixel ou segmento) à classe, cujas amostras são mais próximas em um espaço de atributos. A média da distância de todas as amostras de uma classe a um segmento no espaço de atributos foi usada como métrica de pertinência deste segmento à classe. Ou seja, o objeto é atribuído à classe que apresenta a menor média da distância euclidiana entre os elementos do objeto e as amostras da classe. Sendo que a proximidade entre as amostras e os objetos é altamente dependente do espaço de atributos, a ferramenta *Feature Space Optimization* do sistema Definiens Developer (Definiens 2009) foi utilizada para encontrar a melhor combinação de atributos, ou seja, aquela em que as amostras de cada classe estão mais próximas entre si e mais distantes das amostras das outras classes.

Apesar das vantagens de classificadores VMP, estes não conferem o controle das regras de classificação ao usuário, a não ser indiretamente através da coleta de amostras, ou seja, são classificadores supervisionados puramente estatísticos. Por esse motivo, o classificador por AD C4.5 também foi testado. Ao contrário do VMP, em geral, a construção de uma AD é realizada segundo alguma abordagem recursiva de particionamento da base de dados (Goldschmidt e Passos 2005). Em uma AD, cada nó interno da árvore representa uma decisão sobre um atributo, que determina como os dados são particionados pelos seus nós-filhos. Cada nó-filho, por sua vez, abrange um particionamento que será novamente particionado até que nos nós-folhas da árvore, os registros pertençam inteiramente ou predominantemente a uma mesma classe (Friedl e Brodley 1997; Goldschmidt e Passos 2005). Ao final, obtém-se uma estrutura hierárquica de regras em forma de limiarização de atributos, que pode ser aplicada sobre a base de dados completa para a realização da tarefa de classificação. Em relação ao VMP, ADs têm a vantagem de permitirem ao usuário visualizar e entender quais atributos e os limiares que estão sendo usados no particionamento dos dados que produzirá a classificação final.

Como uma terceira abordagem de classificação, o classificador por AD C4.5 foi combinado com o classificador VMP do sistema Definiens Developer. Inicialmente, a rede hierárquica e semântica mostrada na **Figura 2** foi elaborada. Para a classificação de corpos d'água (água e não-água), assim como para a classificação de vegetação e

não-vegetação, foi usado o algoritmo C4.5. Em seguida, o VMP foi usado duas vezes: a primeira para a separação entre vegetação Ripária e Cerrado e a segunda para a separação entre Solo Exposto e Queimada (**Figura 2**).



**Figura 2.** Rede hierárquica elaborada para a abordagem mista de classificação.

#### 4. Resultados e Discussão

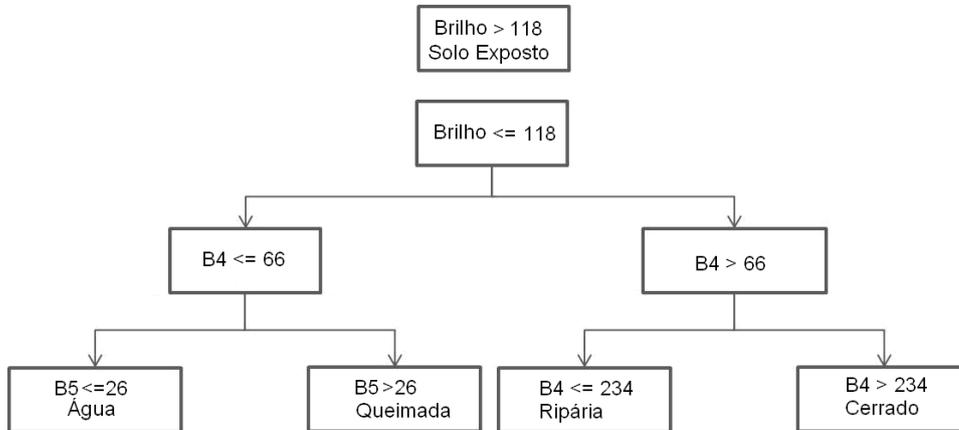
Previamente à classificação utilizando o algoritmo VMP e considerando as cinco classes de interesse, as amostras das classes foram inseridas na ferramenta *Feature Space Optimization*. No total, 35 atributos espectrais foram submetidos à seleção, e o número máximo de dimensões também foi fixado em 35. Ao final do processo, 17 atributos foram selecionados como aqueles em que as amostras das classes encontram-se mais distantes das amostras das outras classes. Estes atributos são: brilho, valor máximo dos pixels na banda 2, valor máximo dos pixels na banda 3, valor máximo dos pixels na banda 4, valor máximo dos pixels na banda 6, média dos pixels na banda 3, média dos pixels na banda 6, valor mínimo dos pixels na banda 3, valor mínimo dos pixels na banda 4, valor mínimo dos pixels na banda 6, divisão da média da banda 4 pela média da banda 3, divisão da média da banda 3 pela média da banda 1, NDVI, razão da banda 3 pela soma de todas as bandas, razão da banda 4 pela soma de todas as bandas e razão da banda 6 pela soma de todas as bandas. A classificação empreendida com o algoritmo VMP atingiu um índice *Kappa* de 0,92, e exatidão global de 94% (Congalton 1991), o que atesta a ótima qualidade da classificação. A **Tabela 1** mostra a matriz de confusão desta classificação enquanto a **Figura 4(a)** mostra o mapa temático produzido.

**Tabela 1.** Matriz de confusão da classificação obtida pelo classificador VMP.

Classe \ Amostra	Água	Cerrado	Ripária	Queimada	SoloExposto	Soma
Água	36	0	0	0	0	36
Cerrado	0	42	0	1	4	47
Ripária	0	2	53	0	0	55
Queimada	0	0	0	46	3	49
SoloExposto	0	3	0	0	69	72
Não classificado	0	0	2	0	0	2
Soma	36	47	55	47	76	
Acurácia do Produtor	1	0,89	0,96	0,97	0,90	
Acurácia do Usuário	1	0,89	0,96	0,93	0,95	
Índice <i>Kappa</i> por Classe	1	0,87	0,95	0,97	0,87	

As regras geradas pelo C4.5 foram então inseridas na descrição das classes na forma

de regras de classificação. Apesar de 35 atributos terem estado disponíveis para o algoritmo C4.5, apenas três atributos foram usados no particionamento dos dados. Isto indica que estes três atributos são de fato bem correlacionados às classes e, assim, uma árvore de decisão simples e pequena foi o suficiente. Esta classificação atingiu uma exatidão global de 83% e um índice *Kappa* de 0,78 (**Tabela 2**), o que atesta a boa qualidade da classificação temática (**Figura 4(b)**). A seguinte AD foi gerada pelo algoritmo C4.5:



**Figura 3.** Árvore de decisão gerada pelo algoritmo C4.5.

**Tabela 2.** Matriz de confusão da classificação obtida pela Árvore de Decisão.

Classe \ Amostra	Água	Cerrado	Ripária	Queimada	SoloExposto	Soma
Água	3	0	0	0	0	33
Cerrado	1	30	0	3	2	36
Ripária	0	4	43	0	0	47
Queimada	1	0	0	41	3	45
SoloExposto	1	13	12	3	71	100
Não classificado	0	0	0	0	0	0
Soma	6	47	55	47	76	
Acurácia do Produtor	0,91	0,63	0,78	0,87	0,93	
Acurácia do Usuário	1	0,83	0,91	0,91	0,71	
Índice <i>Kappa</i> por Classe	0,90	0,58	0,73	0,84	0,89	

Na abordagem mista de classificação, o C4.5 classificou com Água os segmentos com o atributo máximo valor da banda 5 abaixo de 54. Os segmentos com valor acima deste limiar passaram a ser classificados como Não-Água. Dentro deste universo, este algoritmo classificou como Vegetação os segmentos com o valor do atributo divisão da média da banda 4 pela média da banda 3 acima de 1,1. Os segmentos com valor abaixo deste limiar passaram a ser classificados como Não-Vegetação. Em seguida, para a classificação de Cerrado e Ripária no universo Vegetação, as amostras destas duas classes foram inseridas na ferramenta *Feature Space Optimization*. No total, 35 atributos foram inseridos, e o número máximo de dimensões definido foi de 10. Ao final do processo, somente o atributo divisão da média da banda 4 pela média da banda 3 foi selecionado, dando a entender que este é um atributo bom para a classificação de vegetação assim como para a separação de diferentes tipos de vegetação. O classificador VMP foi então aplicado para a classificação de Ripária e Cerrado na área previamente classificada como Vegetação pelo C4.5. O mesmo processo foi aplicado para as amostras de Áreas Queimadas e Solo Exposto. Os atributos selecionados pelo *Feature Space Optimization* foram: brilho (*brightness*), média dos pixels na banda 3, média dos pixels na banda 5, valor máximo dos pixels na banda 4 e valor mínimo dos pixels na banda 3. O classificador VMP foi então aplicado neste espaço de atributos na porção da imagem classificada como Não-Vegetação pelo C4.5. Por último, o mesmo processo foi aplicado para as amostras



## 5. Conclusões

Este estudo demonstrou o potencial do uso de classificação orientada a objeto como uma ferramenta eficaz para o mapeamento de queimadas e outras classes de cobertura da terra no Pantanal. O modelo desenvolvido com base em informações da própria região de estudo apresentou bons resultados para uma área bastante heterogênea, representativa do bioma Pantanal. É válido mencionar que este método depende da disponibilidade de plataformas orientadas a objeto, bem como de intérpretes treinados para operá-las e, obviamente, com conhecimento aprofundado sobre a área a ser investigada. As três abordagens consideradas mostraram bastante variação para a discriminação entre vegetação (Ripária e Cerrado) e Solo Exposto. Porém, as queimadas e os corpos d'água apresentaram certa uniformidade nas três classificações. Como os alvos de maior interesse são as queimadas, pode-se considerar que a classificação produzida pelos três métodos foi satisfatória, e ao considerar as demais classes presentes na cena, as tabelas de contingência produzidas indicam que a classificação por VMP foi a que gerou o melhor resultado dentre os métodos analisados.

A justificativa em prol do uso de plataformas orientadas a objeto reside na versatilidade exploratória dos dados de entrada, o que permite ao intérprete um entendimento mais profundo do objeto de estudo, em vista da consideração de uma gama diversificada de atributos. Outro argumento a favor do emprego desses sistemas consiste no caráter replicável da rede de classificação para outras áreas de estudo, não necessariamente com as mesmas dimensões, mas com configurações de paisagem semelhantes, uma vez que o sistema permite o ajuste das funções e seus limiares, a fim de garantir a conformidade da rede à realidade em análise, economizando assim esforços de modelagem por parte do intérprete e tempo de processamento computacional. Embora os resultados preliminares desenvolvidos para dados *TM-Landsat* pareçam ser promissores, uma investigação e avaliação mais aprofundadas são necessárias para que o método proposto possa ser considerado suficientemente robusto para uso operacional e em larga escala. Assim sendo, os autores pretendem em trabalhos futuros aplicar a metodologia aqui apresentada em outras áreas do Pantanal, com características fitogeográficas diversas da região estudada neste experimento, e possivelmente, no bioma Pantanal como um todo.

## 6. Agradecimentos

Os autores externam seus agradecimentos à CAPES, pela concessão de bolsa de doutorado a Daniel Zanotta; à FAPESP, pela concessão de bolsa de doutorado a Hiran Zani, e ao CNPq, pela concessão de bolsa de doutorado a Samuel Coura.

## 7. Referências

- Gitas, I.Z.; Mitri, G.H.; Ventura, G. Object-based image classification for burned area mapping of Creus Cape, Spain, using NOAA-AVHRR imagery. **Remote Sensing of Environment**, v. 92, n. 3, p. 409-413. 2004.
- Lashof, D.A. The contribution of biomass burning to global warming: an integrated assessment. In: Levine, J.S. (Ed) **Global biomass burning**, Cambridge: MIT Press, 1996. p. 441-444.
- Levine, J.S.; Wesley III, R.C.; Winstead, E.L.; Thinehart, R.P.; Cahoon Jr., D.R.; Sebacher, D.K.; Sebacher, S.; Stocks, B.J. Biomass burning: combustion emissions, satellite imagery, and biogenic emissions. . In: Levine, J.S. (Ed) **Global biomass burning**, Cambridge: MIT Press, 1996. p. 264-271.

- Grace, J. Understanding and managing the global carbon cycle. **Journal of Ecology**, v. 92, n. 2, p. 189-202. 2004.
- Caetano, M.S.; Mertes, A.K.; Pereira, M.C. Using spectral mixture analysis for fire severity mapping. In: **2<sup>nd</sup> International Conference on Forest Fire Research**, Coimbra. 2004. pp. 667–677.
- Pereira, M.C.; Chuvieco, E.; Beudoin, A.; Desbois, N. Remote sensing of burned areas: a review. In: E. Chuvieco (Ed.) **A review of remote sensing methods for the study of large wildland fires**. 1997. pp. 127– 184.
- Gonçalves, D. A.; Júnior, W.C.S.; Morelli, F. Identificação e delimitação de áreas queimadas no Pantanal. **Anais... 1º Simpósio de Geotecnologias no Pantanal**, Campo Grande, Brasil, 2006, p. 622-627.
- Zanotta, D.C. Detecção de queimadas a partir de técnicas semi-automáticas e operadores morfológicos de erosão/dilatação usando imagens de sensoriamento remoto. **Geografia (Rio Claro. Impresso)**, v. 34, p. 817- 824, 2009.
- Chuvieco, E. **Remote sensing of large wildfires in the European Mediterranean Basin**, New York: Springer-Verlag, 1999.
- Justice, C.O.; Giglio, B.; Korontzi, S.; Owens, J.; Morisette, J.T.; Roy, D.P.; Descloitres, J.; Alleaume, S.; Petitcolin, F.; Kaufman, Y. The MODIS fire products. **Remote Sensing of Environment**, v. 83, pp. 244-262, 2002.
- Baatz, M.; Schäpe, A. Object-oriented and multi-scale image analysis in semantic networks. In 'Proceedings of the 2nd international symposium on operationalization of remote sensing, Enschede, ITC, The Netherlands, 16–20 August'. 1999. Enschede: ITC, 2000.
- USGS. **United States Geological Service**. 2010. Disponível em: <[http://edcns17.cr.usgs.gov/helpdocs/landsat/product\\_t\\_descriptions.html](http://edcns17.cr.usgs.gov/helpdocs/landsat/product_t_descriptions.html)>. Acessado em 28 de Abril de 2010.
- Frouin, R.; Schwindling, M.; Deschamps, P. Y. Spectral reflectance of sea foam in the visible and near-infrared: in situ measurements and remote sensing implications. **Journal of Geophysical Research**, v. 101, n. c6, pp. 14361–14371, 1996.
- Frazier, P.S.; Page, K.J. Water body detection and delineation with Landsat TM data. **Photogrammetric Engineering and Remote Sensing**, v. 66, n. 12, p. 1461–1467, 2000.
- Chander, G.; Markham, B.L. Helder, D.L. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. **Remote Sensing of Environment**, v. 113, n. 5, 893-903, 2009.
- Chavez, P. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v. 24, n. 3, p. 459-479, 1988.
- Mitri, G. H.; Gitas, I. Z. A performance evaluation of a burned area object-based classification model when applied to topographically and non-topographically corrected TM imagery, **International Journal of Remote Sensing**, v. 25, n. 14, p. 2863-2870. 2004.
- Quinlan, R., C4.5: Programs for Machine Learning. San Francisco: Morgan Kaufmann, 1993.
- Definiens. **Definiens Developer User Guide**. Desenvolvido por Definiens®. Alemanha, 2003-2009. Disponível em: <<http://www.definiensimaging.com/down/ecognition>>. Acessado em: 15 out. 2007.
- Goldshmidt, R.; Passos, E. **Data mining – um guia prático**. Rio de Janeiro: Elsevier, 2005. 257 p.
- Friedl, M.; Brodley, C. Decision tree classification of land cover from remotely sensed data. **Remote Sensing of Environment**. v. 61, n. 3, p.399– 409, 1997.
- Congalton, R. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35–46, 1991.