

Um método para modelagem de conhecimento multitemporal no processo de classificação automática de imagens de sensores remotos

Vanessa de Oliveira Campos¹
Raul Queiroz Feitosa^{1,2}
Guilherme Lucio Abelha Mota²
Marco Aurélio Cavalcanti Pacheco^{1,2}
Heitor Luiz da Costa Coutinho³

¹Pontifícia Universidade Católica do Rio de Janeiro – PUC-RJ
Rua Marquês de São Vicente 225, Gávea, Rio de Janeiro, CEP 22453-900, RJ, Brasil
{vanessa, raul, guimota, marco}@ele.puc-rio.br

²Universidade do Estado do Rio de Janeiro – UERJ
Rua São Francisco Xavier 524, Maracanã, Rio de Janeiro, CEP 20550-900, RJ, Brasil

³Empresa Brasileira de Pesquisa Agropecuária – EMBRAPA Solos
Rua Jardim Botânico 1024, Jardim Botânico, Rio de Janeiro, CEP 22460-000, RJ, Brasil
heitor@cnps.embrapa.br

Abstract: The present work proposes a methodology to model multitemporal knowledge within an automatic image interpretation framework. The method uses state transition diagrams to express the possibilities of class changes within a given time span. The change possibilities are estimated upon data of the same region acquired at a previous date by using genetic algorithms. Classification results obtained from multitemporal reasoning are combined to pure spectral classification by using fuzzy logic techniques. The proposed approach was evaluated using LANDSAT 7 images of three consecutive years of an area in southwest Brazil showing encouraging results. The multitemporal knowledge always improved the classification performance in comparison to a pure spectral classification. Moreover the genetic algorithm was in all cases superior to the manual trial and error alternative for the parameter estimation of the multitemporal model.

Palavras-chave: remote sensing, knowledge based interpretation, multitemporal knowledge, digital image processing, sensoriamento remoto, interpretação baseada em conhecimento, conhecimento multitemporal, processamento digital de imagens.

1. Introdução

Imagens de sensores orbitais com resoluções espectrais e espaciais cada vez maiores têm sido disponibilizados para o monitoramento de grandes áreas em todo o planeta. Contudo, o processo de interpretação destas imagens é ainda predominantemente manual. Decorre daí a demanda por ambientes computacionais de alto nível que automatizem fases do processo de interpretação. As abordagens mais promissoras nesta direção consistem em modelar explicitamente o conhecimento que um foto-intérprete aplica ao analisar visualmente as imagens (Müller et al. (2003), Pakzad et al. (2003), Mota et al. (2003, 2004b), Mota (2004a), Cazes et al. (2004)). Entre as diversas formas de conhecimento que pode ser utilizado com este propósito o chamado conhecimento multitemporal é particularmente importante.

Dentro deste contexto, o presente trabalho propõe um procedimento para a modelagem de conhecimento multitemporal e sua integração com outras formas de conhecimento num ambiente integrado para a interpretação automática de imagens de sensores remotos. A proposta consiste em utilizar diagramas de transição de estado para expressar a relação entre a classe de um objeto num dado momento e a classe do mesmo objeto num instante anterior.

De fato, diagramas de transição de estado já têm sido utilizados em trabalhos anteriores como ferramenta para modelar conhecimento multitemporal. Em Bückner et al. (1999) e Gro-

Grove et al. (2000), os diagramas são usados apenas para identificar as alterações de classes possíveis e desta forma restringir o número de classes a considerar para cada segmento no processo de classificação. Já em Pakzad (2001) e Grove (2001), as transições estão associadas a um valor que expressa a possibilidade de ocorrência da transição, como nesta proposta. Contudo, os valores de possibilidade nestes trabalhos são usados meramente para estabelecer a ordem da procura de uma solução dentro de uma rede semântica que representa o processo de interpretação da imagem. Os diagramas melhoram, nesta abordagem apenas o desempenho computacional e não afetam o desempenho da classificação propriamente dito.

A presente proposta utiliza os valores de possibilidade de transição representados no diagrama como parâmetros das funções discriminantes. Estes valores são estimados utilizando algoritmos genéticos (AG) a partir de dados de datas anteriores à da imagem analisada. No processo de classificação, os resultados obtidos da aplicação do conhecimento multitemporal são combinados com outras formas de conhecimento (p. ex. espectral) lançando mão de ferramentas da Lógica Nebulosa (Zadeh (1965, 1978), Kuncheva (2000), e Mendel (1995)).

Este trabalho está organizado da seguinte forma. A seção 2 apresenta o procedimento de interpretação proposto. Na seção 3, é descrita a utilização de algoritmos genéticos para estimar os parâmetros que representam o conhecimento multitemporal. A seção 4 apresenta uma avaliação da presente proposta. Finalmente, na seção 5, são apresentadas as conclusões.

2.Procedimento de Interpretação

2.1. Descrição Geral

A **Figura 1** apresenta a visão geral do procedimento de interpretação proposto neste trabalho. Consideram-se aqui dados referentes ao instante t em que foi adquirida a imagem a ser interpretada, e um instante anterior $t-\Delta t$, onde Δt denota o tempo transcorrido entre eles.

Ao invés da classificação usual de pixels utiliza-se a classificação de segmentos, cujas vantagens são discutidas p. ex. em Andrade et al. (2003), Darvish et al. (2003) e Yan (2003). A fim de produzir a interpretação da imagem obtida em t , utiliza-se como entrada os segmentos da área de interesse em t , a interpretação em $t-\Delta t$, além do conhecimento espectral e do conhecimento multitemporal. O termo conhecimento espectral se refere aqui à modalidade de conhecimento que expressa relações entre a resposta espectral do segmento na imagem adquirida em t (imagem analisada) e as classes da legenda. O conhecimento multi-temporal baseia-se em informações do segmento em instantes anteriores. No modelo aqui proposto, a informação multitemporal relevante é a classe a que o segmento pertencia em $t-\Delta t$.




Figura 1 – Visão geral do procedimento de interpretação

O procedimento de interpretação calcula dois graus de pertinência para cada segmento e

cada classe, produzidos respectivamente pela aplicação do conhecimento espectral e multitemporal. A regra de decisão adotada consiste em atribuir o segmento à classe cujo produto destes dois graus de pertinência é máximo.

2.2. Modelagem do Conhecimento Multitemporal

O conhecimento multitemporal expressa nesta proposta a possibilidade de um dado segmento da imagem em t pertencer a uma determinada classe, tendo em vista a classe a qual pertencia em $t-\Delta t$. Desta forma, atribui-se a cada transição de classes um valor d_{ij} entre zero e um, que expressa a possibilidade, no sentido da teoria das possibilidades Zadeh (1978), de que um segmento associado à classe ω_i num instante passe a pertencer à classe ω_j , Δt unidades de tempo mais tarde, onde $i, j = 1, \dots, p$, e p é o número de classes da legenda. O conhecimento multitemporal pode ser modelado por um diagrama de transição de estados, como ilustra a **Figura 2**. Trata-se de um grafo, cujos nós representam as classes da legenda e os arcos as possíveis mudanças de classe que um segmento pode sofrer entre dois instantes de tempo separados por Δt . Associado a cada arco tem-se os valores de possibilidade de ocorrência de cada transição.




Figura 2 – Exemplo de modelagem de conhecimento multitemporal usando diagrama de transição de estados.

Estimar o valor destas possibilidades representa uma dificuldade importante mesmo para um especialista com grande conhecimento da área. Neste trabalho, propõe-se um método semi-automático de estimação destes valores, como se segue.

Primeiramente o especialista da área analisada define as transições impossíveis. Estas transições têm possibilidade nula e os arcos correspondentes são suprimidos do diagrama. Em seguida o especialista determina para cada classe a transição (arco emergente) com maior possibilidade de ocorrência; a esta transição atribui-se valor 1. Na maioria dos casos práticos, esta transição corresponde à permanência na mesma classe, como nos casos ilustrados na **Figura 2**. Os demais valores de possibilidade de transição devem ser estimados a partir de dados históricos utilizando algum método de otimização como descrito na próxima seção.

3. Busca de Parâmetros Através de Algoritmos Genéticos

A busca dos valores de possibilidade de transição d_{ij} , nesta proposta, é realizada utilizando algoritmos genéticos (AG), Holland (1975). A **Figura 3** apresenta a visão geral do algoritmo de busca dos parâmetros através de algoritmos genéticos. Seguindo esta metodologia, a busca dos valores de d_{ij} será realizada pela seguinte seqüência de passos: **1)** Inicialização da população – vários conjuntos de valores d_{ij} são gerados aleatoriamente; **2)** Cálculo da avaliação dos indivíduos da população – aplica-se uma função de avaliação a cada conjunto; **3)** Produção de

uma nova geração – os conjuntos com melhor avaliação são alterados de modo a produzir um novo conjunto de valores para d_{ij} ; neste passo observam-se as restrições definidas pelo analisista humano quanto às transições mais prováveis e impossíveis 4) Os passos 2 e 3 são repetidos por um número finito de gerações.




Figura 3 - Visão geral do procedimento de busca das possibilidades das transições – parâmetros do conhecimento multitemporal.

Resta ainda esclarecer como se avaliam os indivíduos a cada geração. Utilizam-se para isso a interpretação de duas imagens da mesma área obtidas em duas datas separadas por Δt , denotas com $t'-\Delta t$ e t' , e ainda a imagem correspondente à data t' . Aplica-se a estes dados o procedimento de interpretação descrito na seção 2, utilizando o conjunto de valores de d_{ij} que está sendo avaliado. A avaliação será dada pela taxa de acerto na classificação, considerando como referência a interpretação da imagem em t' .

4. Avaliação de Desempenho

Esta seção descreve o protótipo do procedimento proposto construído em software e os resultados de uma avaliação de desempenho realizada a partir de dados reais.

4.1. Descrição do Protótipo

O primeiro passo realizado pelo protótipo consiste em segmentar as imagens de entrada. O algoritmo empregado na segmentação se baseia no método *watersheds* (divisor de águas), descrito em Vincent e Soille (1991) e Gonzalez e Woods (1992). Os modelos para os conhecimentos espectral e multitemporal foram construídos como descrito a seguir.

4.1.1. Modelagem do Conhecimento Espectral

O conhecimento espectral será representado por um conjunto de funções que aplicadas à resposta espectral média de um segmento produz os graus de pertinências a cada classe da legenda. Diversas alternativas para a construção destas funções podem ser adotadas. Neste protótipo, adotou-se o seguinte procedimento.

Primeiramente, selecionam-se amostras de segmentos para cada uma das classes do problema, o chamado conjunto de treinamento. Esta seleção pode ser feita manualmente como no método supervisionado convencional. No presente trabalho, as amostras foram selecionadas pelo método automático proposto em Cazes et al. (2004).

A partir do conjunto de treinamento estimam-se as média $\mathbf{m}_i$, e as matrizes de covariância Σ_i de cada classe. Admite-se neste trabalho que a resposta espectral média dos segmentos de cada classe pode ser adequadamente modelada por uma distribuição Normal $N(\mathbf{m}_i, \Sigma_i)$.

Para construir as funções de pertinência relativas à resposta espectral, explora-se uma propriedade das distribuições normais, segundo a qual a distância de mahalanobis ao centróide de uma população com distribuição $N(\mathbf{m}_i, \Sigma_i)$ é uma variável aleatória com distribuição chi-quadrado com p graus de liberdade, onde p é a dimensão do espaço de atributos. Decorre daí que a probabilidade de que um padrão $\mathbf{x}$ pertencente à população ω_i esteja a uma distância

$$(\mathbf{x} - \mathbf{m}_i)^T \Sigma_i^{-1} (\mathbf{x} - \mathbf{m}_i) < \chi_p^2(\gamma) \quad \text{Equação 1}$$

da média $\mathbf{m}_i$ é igual a $(1-\gamma)$, onde $\chi_p^2(\gamma)$ é o percentil (100γ) da função chi-quadrado com p graus de liberdade, Duda (2001). O grau de pertinência é dado, portanto, pelo valor de γ que satisfaz a equação abaixo:

$$(\mathbf{x} - \mathbf{m}_i)^T \Sigma_i^{-1} (\mathbf{x} - \mathbf{m}_i) = \chi_p^2(\gamma) \quad \text{Equação 2}$$

4.1.2. Estimativa dos Parâmetros Relativos ao Conhecimento Multitemporal

O algoritmo genético emprega como função de avaliação a média das taxas de classificação classe a classe, conforme apresentado na **Equação 3**.

$$A = (T_1 + T_2 + \dots + T_n)/n$$

$$T_i = C_i/n_i, i = 1, 2, \dots, n \quad \text{Equação 3}$$

onde A é a avaliação do indivíduo; n é o número total de classes; T_i é a taxa de reconhecimento da classe ω_i , C_i é o total de elementos da classe ω_i classificados corretamente e n_i é o total de elementos da classe ω_i .

A produção de uma nova população é feita através da substituição dos M piores indivíduos da população anterior, sendo M um número inteiro menor que o tamanho da população. Os novos indivíduos são gerados por reprodução, que toma como base os genes de indivíduos selecionados da população anterior. Na avaliação da aptidão, foi utilizada a normalização linear, Davis (1990). Foram utilizados os seguintes operadores genéticos: *Crossover simples* - dois indivíduos trocam entre si partes de seus cromossomos, Davis (1990) e Michalewicz (1994); *crossover aritmético* - combinação linear de dois indivíduos; *mutação* - altera aleatoriamente um gene do indivíduo, Davis (1990) e Michalewicz (1994); dois tipos de *mutação creep*, Davis (1990), que atuam na busca de uma solução próxima da resultante através de ajustes aleatórios sendo a primeira com ajuste pequeno e a segunda com ajuste grande. Na reprodução, cada operador genético pode ser sorteado pelo mecanismo de roleta em função de sua respectiva probabilidade de aplicação. No presente algoritmo genético, a fim de acelerar o processo evolutivo, foi realizada a interpolação, Davis (1990), destas probabilidades ao longo do processo evolutivo.

4.2. Descrição do Experimento

4.2.1. Base de Dados

Como base de dados para validação da metodologia aqui proposta, foram empregados dados referentes a duas áreas da Alta Bacia do Rio Taquari a leste do pantanal mato-grossense, as mesmas utilizadas nos experimentos em Mota (2004a). As áreas são cobertas por uma única cena LANDSAT, cena 224-073. As imagens das áreas – composição das bandas 5, 4 e 3 do sensor ETM carregado pelo satélite LANDSAT 7 nos canais R, G e B respectivamente – foram adquiridas em 5 de agosto de 1999, 7 de agosto de 2000 e 10 de agosto de 2001.

Os resultados de referência utilizados nos experimentos foram obtidos por interpretação visual realizada por um foto-intérprete especialista em classificação de cobertura vegetal e conhecedor da área de teste. Foi utilizado nesta tarefa, além das imagens, uma videografia realizada em outubro de 2001.

4.2.2. Classes da Legenda

São as seguintes as classes de interesse e suas respectivas descrições: ω_1) *solo exposto*, solo que tenha sido degradado por erosão ou que esteja sendo preparado para o cultivo. ω_2) *mata ciliar*, floresta densa ao longo de rios e córregos. ω_3) *pasto*, pasto cultivado para a alimentação de bovinos. ω_4) *corpos d'água*, água aparente ou região pantanosa. ω_5) *cerradão*, floresta de savana densa. ω_6) *cerradão em regeneração*, área anteriormente usada como pasto, deixada de lado pelo proprietário e por isso, agora, a cobertura vegetal original está se regenerando.

4.3. Procedimento Experimental

Os resultados produzidos pelo método proposto são comparados com os resultados de em Mota (2004a), obtidos a partir do ajuste manual dos parâmetros num processo de tentativa e erro. Durante busca de parâmetros pelo AG foram utilizados dados de 1999 e 2000. A avaliação dos indivíduos foi a taxa de acerto relativamente na classificação de referência da imagem de 2000. Usando os parâmetros obtidos nesta etapa, uma imagem de 2001 foi classificada aplicando o método proposto e os resultados obtidos comparados com a interpretação visual desta imagem. Os experimentos foram executados vinte vezes. Para cada um destes experimentos foi escolhido o melhor indivíduo ao longo de 100 gerações.

classe	taxa de reconhecimento (%)				
	classificação puramente espectral	com conhecimento multitemporal			
		ajuste manual de parâmetros	ajuste de parâmetros por AG		
			pior caso	média	melhor caso
<i>Solo exposto</i>	49,1	54,1	83,5	85,3	88,5
<i>Mata ciliar</i>	82,5	100,0	100,0	100,0	100,0
<i>Pasto</i>	54,3	91,3	93,5	93,5	93,5
<i>Corpos d'água</i>	100,0	100,0	100,0	100,0	100,0
<i>Cerradão</i>	75,8	96,2	98,5	99,0	100,0
<i>Cerradão em reg.</i>	50,0	50,0	50,0	91,7	100,0
Média	68,6	81,9	87,9	94,6	97,0

Tabela 1 – Taxas de reconhecimento obtidas na classificação da imagem de 2001.

4.3.1. Análise dos Resultados

A **Tabela 1** apresenta as taxas de reconhecimento classe a classe da classificação puramente espectral e pela inclusão do conhecimento multitemporal. A primeira observação importante é o ganho expressivo trazido pela introdução do conhecimento multitemporal; a taxa média de acerto passa de 68,6% para valores entre 82% e 97%. A tabela mostra também a eficiência do algoritmo genético relativamente à busca manual das possibilidades de transição. Dentre os indivíduos das vinte execuções do AG, são apresentados na tabela o resultado pior, médio e melhor. Observa-se que as médias das taxas de classificação produzidas com os conjuntos de parâmetros fornecidos pelo AG foram sempre superiores às obtidas com os parâmetros ajustados manualmente. Considerando o resultado classe a classe, as taxas de classificação foram no mínimo equivalentes às produzidas com base nos parâmetros selecionados manualmente. Este fato ocorreu com o pior indivíduo para a classe *cerradão em regeneração*, contudo o desempenho médio do método via AG foi consideravelmente superior ao do ajuste manual

dos parâmetros. Além disso, para o melhor indivíduo foi possível atingir 100%.

Para as classes *mata ciliar* e *corpos d' água*, os parâmetros escolhidos manualmente já haviam possibilitado a obtenção de 100% de taxa de classificação. Tanto o melhor quanto o pior indivíduo produziu 100% de taxa de classificação para estas classes. Para as classes *pasto* e *cerradão*, os resultados produzidos com os conjuntos de parâmetros fornecidos pelo algoritmo genético ultrapassaram significativamente os obtidos com os parâmetros ajustados manualmente. Para a classe *solo exposto*, mesmo no pior caso, o desempenho foi muito superior ao obtido pelo ajuste manual, passando de 54,1% para 83,5% no pior caso.

Os resultados destes experimentos sugerem que, além de automatizar e acelerar a modelagem do conhecimento, o uso de algoritmos genéticos pode possibilitar resultados superiores aos parâmetros ajustados manualmente.

5. Conclusão

O presente trabalho apresentou um método de modelagem de conhecimento multitemporal para a interpretação automática de imagens de sensores remotos. O método utiliza a informação da classe de um objeto num instante anterior e estimativas da possibilidade de transição entre classes no intervalo de tempo considerado. Estas estimativas são obtidas aplicando algoritmos genéticos a um conjunto de dados da mesma área relativos dois instantes de tempo separados pelo mesmo intervalo. Uma avaliação experimental do método a partir dados reais indicou que o método melhorou a taxa de classificação média de 68% para valores entre 88% e 97%. Além de constituírem um método automático, os algoritmos genéticos foram superiores também em termos de desempenho na classificação em relação à estimativa manual dos parâmetros do modelo multitemporal.

Os resultados experimentais encontrados sugerem que maiores benefícios podem ser alcançados pela incorporação de conhecimento contextual ao procedimento de classificação. Questões importantes para trabalhos futuros são a avaliação de outros métodos de otimização e a possibilidade de enriquecer o modelo multitemporal, de modo a acelerar a convergência do AG e a melhorar o desempenho da classificação. Análises de desempenho usando dados de outros sítios são ainda necessárias para uma apreciação definitiva do método.

Agradecimento

Os autores agradecem à CAPES e ao DAAD pelo apoio no âmbito do programa PROBRAL.

Referências

- Andrade, A.; Botelho, M. F.; Centeno, J. Classificação de imagens de alta resolução integrando variáveis espectrais e forma utilizando redes neurais artificiais. In: Simpósio Brasileiro de Sensoriamento Remoto, 11., 2003, Belo Horizonte. **Anais...** São José dos campos: INPE, 2003. p. 1099-1106.
- Bückner, J.; Jung, S.; Pakzad, K. Image Interpretation and GIS Analysis as an Approach for Moor Monitoring. In: International Conference on Dynamic and Multi-Dimensional GIS DMGIS 99, 1999, Pequim, China. **Proceedings...** Pequim, China, 1999, p. 341-349.
- Cazes, T.B.; Feitosa, R.Q.; Mota, G.L.A. Automatic Selection of Training Samples for Multitemporal Image Classification. In: International Conference on Image Analysis and Recognition - ICIAR 2004, Setembro de 2004, Porto, Portugal. **Proceedings...** Porto, Portugal, 2004.
- Davis, L., **Handbook of Genetic Algorithms**, VNR Comp. Library, 1990.
- Darwish, A.; Leukert, K.; Reinhardt, W. Image Segmentation for the Purpose of Object-Based Classification, In: IGARSS 2003, julho de 2003, Toulouse. **Proceedings...** Toulouse, julho de 2003. Não paginado.
- Goldberg, D., **Genetic Algorithms in Search, Optimization and Machine Learning**, Addison-Wesley 1989.

Gonzalez, R. C., Woods, R. E., **Digital Image Processing**, 2nd Ed, MA: Addison-Wesley, 2002.

Growe, S.; Shröder, T.; Liedtke, C.-E. Use of Bayesian networks as judgement calculus in a knowledge based image interpretation system, In: 19th Congress of the International Society of Photogrammetry and Remote Sensing, Julho de 2000, Amsterdam, Holanda. **Proceedings...**, v. XXXIII, Amsterdam, 2000.

Growe, S. **Wissensbasierte Interpretation multitemporaler Luftbilder**, Hannover, Alemanha, 2001, Tese de Doutorado, Institut für Theoretische Nachrichtentechnik und Informationsverarbeitung - Universidade de Hannover, 2001.

Holland J.H. **Adaptation in natural and artificial system**, Ann Arbor, The University of Michigan Press, 1975.

Koza, J., **Genetic Programming: On the Programming of Computers by Means of Natural Selection**, MIT Press, 1992.

Kuncheva, L. I. How good are fuzzy if-then classifiers? **IEEE Transactions on Systems, Man, and Cybernetics**. Part B: Cybernetics, v. 30, n. 4, 2000, p. 501-509.

Mendel, J.M., Fuzzy Logic Systems for Engineering: a Tutorial, **Proc. IEEE**, v. 83, n. 3, 1995.

Michalewicz, Z., **Genetic Algorithms+Data Structures=Evolution Programs**, Springer-Verlag-1994.

Mota, G., Müller, S., Feitosa, R., Coutinho, H., Meireles, M., Vieira, H. An Evaluation of Knowledge-Based Interpretation Applied to Low-Resolution Satellite Images. In: IEEE International Geoscience and Remote Sensing Symposium - IGARSS 2003, 2003, Toulouse, França. **Proceedings...**, Toulouse, France, 2003.

Mota, G. L. A. **Interpretação baseada em conhecimento aplicada a imagens multitemporais de satélite de baixa resolução**. Tese de Doutorado, PUC-RIO, Departamento de Engenharia Elétrica, 2004a.

Mota, G. L. A.; Pakzad, K.; Müller, S.; Meireles, M. S. P.; Feitosa, R. Q.; Coutinho, H. L. da C. A Framework for Automatic low-resolution Satellite Image Interpretation Based on Spectral, Contextual and Multitemporal Knowledge. In: XXth Congress of the International Society for Photogrammetry and Remote Sensing, 12-23 de Julho de 2004, Istanbul, Turquia **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 34, Part XXX. 2004b.

Müller, S., Feitosa, R. Q., Mota, G. L. A., Costa, D., Silva, V. V., Tanisaki, K., GEOAIDA Applied to SPOT Satellite Image Interpretation, URBAN 2003. **Proceedings...** Berlim, 22 e 23 de maio 2003.

Pacheco, M. A. C., **Algoritmos Genéticos: Princípios e Aplicações**. Apostila disponível em: <http://www.ica.ele.puc-rio.br>.

Pakzad, K. **Wissensbasierte Interpretation von Vegetationsflächen aus multitemporalen Fernerkundungsdaten**. Hannover, Alemanha, 2001. Tese de Doutorado, Institut für Theoretische Nachrichtentechnik und Informationsverarbeitung -Universidade de Hannover, 2001.

Pakzad, K., Mota, G., Meireles, M., Coutinho, H., Feitosa, R. Automatic Interpretation of Vegetation Areas in Brazil. The Joint Workshop of ISPRS Working Groups I/2, I/5, IC WG II/IV and the EARSeL Special Interest Group 3D Remote Sensing "High Resolution Mapping from Space 2002", **Proceedings...**, Hannover, 2003.

Vincent, L.; Soille, P. Watersheds in digital spaces: an efficient algorithm based on immersion simulations. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.13, p.583-598, jun. 1991.

Yan, G. **Pixel based and object oriented image analysis for coal fire research**. Enschede, Holanda, 2003. Dissertação de Mestrado ITC International Institute for Geo-Information Science and Earth Observation, Holanda, 2003.

Zadeh, L. A. Fuzzy Sets. **Information and Control** 8 (3), 338-353, 1965.

Zadeh, L. A. Fuzzy sets as a basis for a theory of possibility. In: **Fuzzy Sets and Systems**, 1:3-28. 1978.