

UM MÉTODO PARA MODELAGEM DO CONHECIMENTO MULTITEMPORAL NO PROCESSO DE CLASSIFICAÇÃO AUTOMÁTICA DE IMAGENS DE SENSORES REMOTOS

*An approach to model multitemporal knowledge
in automatic classification process of remote sensors images*

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
Departamento de Engenharia Elétrica
Rua Marquês de São Vicente 225, Gávea, CEP 22453-900, Rio de Janeiro - RJ, Brasil
{vanessa, raul, guimota, marco}@ele.puc-rio.br

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

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

RESUMO

O presente trabalho apresenta uma metodologia para modelar conhecimento multitemporal em classificação automática de imagens. Este método utiliza diagramas de transição de estado para representar as possibilidades de mudanças de classe dentro de um determinado intervalo de tempo. As possibilidades de mudança são estimadas a partir de dados previamente adquiridos da mesma região usando algoritmos genéticos. Os resultados da classificação são obtidos pela combinação dos conhecimentos multitemporal e espectral usando técnicas da lógica nebulosa. O método proposto apresentou bons resultados quando testado utilizando imagens LANDSAT 7 de três anos consecutivos de uma área no sudoeste do Brasil. O conhecimento multitemporal sempre melhorou o desempenho da classificação em comparação à classificação puramente espectral. Além disso, o algoritmo genético foi, em todos os casos, superior à alternativa manual de tentativa e erro para estimar parâmetros do modelo multitemporal.

Palavras chaves: sensoriamento remoto, interpretação baseada em conhecimento, conhecimento multitemporal, processamento digital de imagens.

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. In addition, the genetic algorithm was in all cases superior to the manual trial and error alternative for the parameter estimation of the multitemporal model.

Keywords: remote sensing, knowledge based interpretation, multitemporal knowledge, digital image processing.

1. INTRODUÇÃO

Imagens cada vez maiores de sensores orbitais com resoluções espectrais e espaciais têm sido disponibilizadas 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 e 2004b; MOTA, 2004a; CAZES *et al.*, 2004). Entre as diversas formas de conhecimento que podem ser utilizadas 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 GROWE *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 GROWE (2001), as transições estão associadas a um valor que expressa a possibilidade de ocorrência da transição. 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. Nesta abordagem, os diagramas melhoram apenas o desempenho computacional e não afetam o desempenho da classificação propriamente dito. O uso dos valores de possibilidade de transição representados no diagrama como parâmetros das funções discriminantes foi introduzido em MOTA (2004a), mas a estimativa destas possibilidades era feita de modo manual. Na presente proposta estes valores são estimados de modo automático 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 (ex. espectral) lançando mão de ferramentas da Lógica Nebulosa (ZADEH, 1965 e 1978; KUNCHEVA, 2000; MENDEL, 1995).

Este trabalho está organizado da seguinte forma. A seção 2 apresenta o procedimento de interpretação utilizado. 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 Fig. 1 apresenta a visão geral do procedimento de interpretação utilizado neste trabalho para avaliar o método proposto. 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, entre outros trabalhos, 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 multitemporal baseia-se em informações do segmento em instantes anteriores. No modelo aqui proposto, a informação multitemporal relevante é a classe à qual o segmento pertencia em $t-\Delta t$.

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.

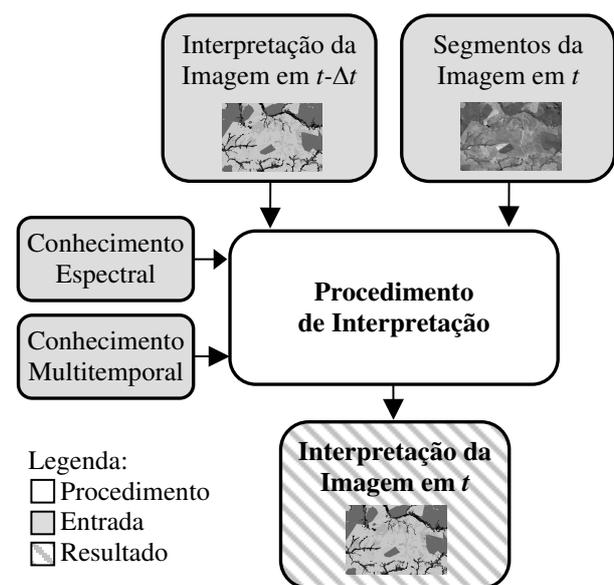


Fig. 1 – Visão geral do procedimento de interpretação.

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 à qual pertencia em $t-\Delta t$.

O presente trabalho procura modelar o conhecimento de um especialista humano quanto às possíveis alterações de classes que ocorrem na área sob análise ao longo do tempo.

Este conhecimento é intrinsecamente subjetivo e, portanto, sujeito a incerteza e inexatidão. Nestes casos, o tratamento possibilístico, conforme a teoria de ZADEH (1978), é mais adequado do que uma abordagem probabilística convencional.

Seguindo esta linha, atribui-se à cada transição de classes um valor d_{ij} entre zero e um, que expressa a possibilidade, no sentido da teoria das possibilidades 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 Fig. 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 o valor de possibilidade de ocorrência da respectiva transição.

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 Fig. 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.

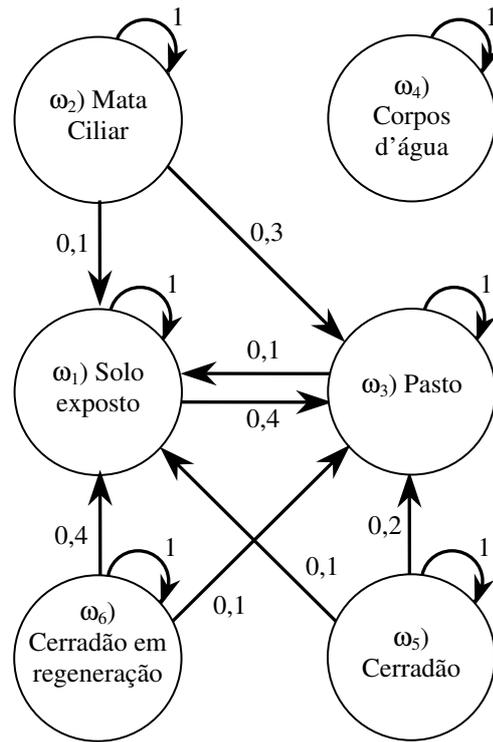


Fig. 2 – Exemplo de modelagem de conhecimento multitemporal usando diagrama de transição de estados.

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). Esta escolha se justifica, tendo em vista que o número total de parâmetros a serem otimizados é limitado superiormente pelo quadrado do número de classes da legenda, e pode, portanto, dependendo da aplicação ser intratável por métodos convencionais.

A Fig. 3 apresenta a visão geral do algoritmo de busca dos parâmetros através de algoritmos genéticos. Na terminologia própria de algoritmos genéticos, um conjunto de valores a serem otimizados corresponde a um indivíduo, neste caso, o conjunto de todos os valores de possibilidade de transição. Um conjunto de indivíduos distintos formam uma população, que a cada geração é submetida a um processo evolutivo. Uma geração é a população formada pela reprodução dos indivíduos da população anterior que são selecionados descartando as soluções menos aptas e privilegiando a escolha dos melhores indivíduos para a reprodução. Os indivíduos gerados reúnem as características de seu(s) antecessor(es) em seus respectivos códigos genéticos. Assim como na natureza – teoria Darwiniana de evolução das espécies (DARWIN, 1859) –, uma população submetida a um ambiente sofrerá influências deste, pois indivíduos mais aptos remetem seus genes um maior número de vezes à próxima geração, por terem maiores condições de

sobreviver e se reproduzir. Portanto, a cada nova geração, a população tenderá a evoluir tornando-se cada vez mais adaptativa ao problema. (HOLLAND, 1975; DAVIS, 1990; MICHALEWICZ, 1994).

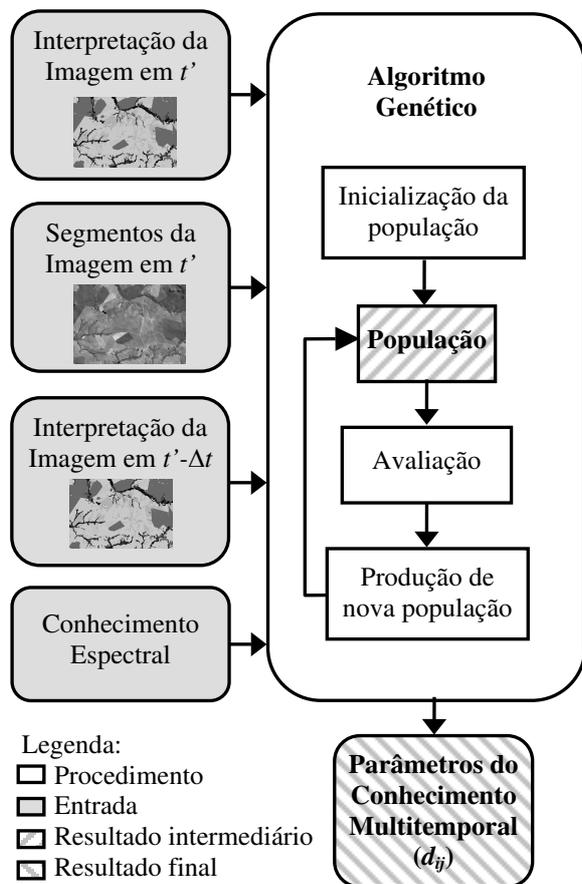


Fig. 3 – Visão geral do procedimento de busca das possibilidades das transições – parâmetros do conhecimento multitemporal.

Seguindo esta metodologia, a busca dos valores de d_{ij} se faz 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 analista humano quanto às transições mais prováveis e impossíveis;
- 4) Os passos 2 e 3 são repetidos por um número finito de gerações.

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 , denotadas 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 & SOILLE (1991) e GONZALEZ & WOODS (2002). Os modelos para os conhecimentos espectral e multitemporal foram construídos como descrito a seguir.

4.1.1. Caracterização 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 procedimento descrito a seguir.

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 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 $N(m_i, \Sigma_i)$.

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 $N(m_i, \Sigma_i)$ é uma variável aleatória com distribuição chi-quadrado com α graus de liberdade, onde α é a dimensão do espaço de atributos. Decorre daí que a probabilidade de que um padrão x pertencente à população ω_i esteja a uma distância

$$(\mathbf{x} - \mathbf{m}_i)^T \Sigma_i^{-1} (\mathbf{x} - \mathbf{m}_i) < \chi_\alpha^2(\gamma) \quad (1)$$

da média m_i é igual a $(1-\gamma)$, onde $\chi_\alpha^2(\gamma)$ é o percentil (100γ) da função chi-quadrado com α graus de liberdade, DUDA (2001). O grau de pertinência é dado, portanto, pelo valor de γ que satisfaz a equação a seguir:

$$(\mathbf{x} - \mathbf{m}_i)^T \sum_i^{-1} (\mathbf{x} - \mathbf{m}_i) = \chi_\alpha^2(\gamma) \quad (2)$$

4.1.2. 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 a seguir:

$$A = (T_1 + T_2 + \dots + T_n)/n \quad (3)$$

$$T_i = C_i/n_i, i = 1, 2, \dots, n$$

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; MICHALEWICZ, 1994); *crossover aritmético* - combinação linear de dois indivíduos; *mutação* - altera aleatoriamente um gene do indivíduo (DAVIS, 1990; MICHALEWICZ, 1994); dois tipos de *mutação creep* 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 (DAVIS, 1990).

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 destas probabilidades ao longo do processo evolutivo (DAVIS, 1990).

4.1.3. Regra de Decisão

Para cada segmento, o procedimento de interpretação calcula um grau de pertinência para cada classe. O grau de pertinência de uma classe ω_i equivale ao produto dos graus de pertinência produzidos pelos conhecimentos espectral e multitemporal correspondentes à classe ω_i . Portanto, cada segmento pertencerá inicialmente a cada classe com um grau de pertinência diferente.

Como mencionado na seção 2.1, a regra de decisão adotada consiste em atribuir o segmento à classe cujo grau de pertinência é máximo.

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 (WRS II 224-073). As imagens das áreas - composição RGB / 5, 4 e 3 do sensor ETM+ - 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 utilizada nesta tarefa, além das imagens, uma videografia realizada em outubro de 2001.

4.2.2. Classes da Legenda

As classes de interesse e suas respectivas descrições são as seguintes:

- 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.

4.3. Procedimento Experimental

Os resultados produzidos pelo método proposto são comparados com os resultados de MOTA (2004a), obtidos a partir do ajuste manual dos parâmetros num processo de tentativa e erro. Durante a busca de parâmetros pelo AG, foram utilizados dados de 1999 e 2000. Como avaliação dos indivíduos foi utilizada a taxa de acerto em relação à 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 foram comparados com a interpretação visual desta imagem.

Algoritmos genéticos são estocásticos, conseqüentemente, seu desempenho pode variar de execução para execução. Por esta razão, os experimentos foram executados vinte vezes. Para cada um destes experimentos foi selecionado o melhor indivíduo ao longo de 100 gerações.

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 87,9% e 97%. A TABELA 2 mostra a eficiência do algoritmo genético quando comparado à busca manual (TABELA 1) das possibilidades de transição. Dentre o grupo composto pelos indivíduos das vinte execuções do AG, a TABELA 2 apresenta os resultados do pior e melhor indivíduos. Além disso, apresenta também os resultados médios obtidos por todos os indivíduos do grupo mencionado.

TABELA 1 – TAXAS DE RECONHECIMENTO OBTIDAS NA CLASSIFICAÇÃO DA IMAGEM DE 2001 SEM A UTILIZAÇÃO DE AG.

classe	taxa de reconhecimento (%)	
	classificação puramente espectral	com conhecimento multitemporal e ajuste manual de parâmetros
ω_1	49,1	54,1
ω_2	82,5	100,0
ω_3	54,3	91,3
ω_4	100,0	100,0
ω_5	75,8	96,2
ω_6	50,0	50,0
Média	68,6	81,9

TABELA 2 – TAXAS DE RECONHECIMENTO OBTIDAS NA CLASSIFICAÇÃO DA IMAGEM DE 2001 COM A UTILIZAÇÃO DE AG.

classe	taxa de reconhecimento (%)		
	com conhecimento multitemporal e ajuste de parâmetros por AG		
	pior caso	média	melhor caso
ω_1	83,5	85,3	88,5
ω_2	100,0	100,0	100,0
ω_3	93,5	93,5	93,5
ω_4	100,0	100,0	100,0
ω_5	98,5	99,0	100,0
ω_6	50,0	91,7	100,0
Média	87,9	94,6	97,0

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* (ω_2) e *corpos d'água* (ω_4), 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 de 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, o uso de algoritmos genéticos foi superior 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, como *simulated annealing* (OTTEN & VAN GINNEKEN, 1991) e redes neurais (HAYKIN, 1999), 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 contribuirão para uma apreciação definitiva do método.

AGRADECIMENTOS

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

REFERÊNCIAS BIBLIOGRÁFICAS

- ANDRADE, A.; BOTELHO, M. F.; CENTENO, J. Classificação de imagens de alta resolução integrando variáveis espectrais e forma utilizando redes neurais artificiais. In: XI SEMINÁRIO BRASILEIRO DE SENSORIAMENTO REMOTO, Belo Horizonte, Brasil, **Anais do XI Seminário Brasileiro de Sensoriamento Remoto**, Belo Horizonte, Brasil, 05-10 abril 2003, INPE, p. 265-272.
- 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 of the International Conference on Dynamic and Multi-Dimensional GIS DMGIS 99**, 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, September 2004, Porto, Portugal. **Proceedings of International Conference on Image Analysis and Recognition - ICIAR 2004**. Porto, Portugal, 2004.
- DAVIS, L., **Handbook of Genetic Algorithms**, VNR Comp. Library, 1990.
- DARWIN, C.; **On the Origin of Species by Means of Natural Selection or the Preservation of Favored Races in the Struggle for Life**. John Murray, 1859.
- DARWISH, A.; LEUKERT, K.; REINHARDT, W. Image Segmentation for the Purpose of Object-Based Classification, In: IGARSS 2003, julho de 2003, Toulouse. **Proceedings of IGARSS 2003**. 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 Congree of the International Society of Photogrammetry and Remote Sensing, Julho de 2000, Amsterdam, Holanda. **Proceedings of IAPRS 2000**, 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.
- HAYKIN, S. **Neural Networks - A Comprehensive Foundation**, Mcmillan College Publishing Co, 1999
- 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 Engeneering: 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., MEIREILES, 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 of IEEE International Geoscience and Remote Sensing Symposium - IGARSS 2003**, 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.; MEIRELLES, 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. In: 2nd Joint Workshop on Remote Sensing and Data Fusion over Urban Areas, Berlin, Alemanha, 22 e 23 de maio 2003. **Proceedings of URBAN 2003**. Alemanha: Technical University Berlin. França: Ecole des Mines de Paris.

OTTEN, R H J M; VAN GINNEKEN, L. P. P. P.; **The annealing algorithm**. Kluwer, Norwell, MA, 1989.

PACHECO, M. A. C., **Algoritmos Genéticos: Princípios e Aplicações**. Apostila disponível em: <http://www.ica.ele.puc-rio.br>. Acesso: 15 de setembro de 2004.

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. L. A.; MEIRELLES, M.; COUTINHO, H.; FEITOSA, R. Q. Automatic Interpretation of Vegetation Areas in Brazil. In: 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“, 2003. **Proceedings of 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“**, 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.