

# Um Método de Classificação Multitemporal em Cascata de Imagens de Sensoriamento Remoto

Gilson Alexandre Ostwald Pedro da Costa <sup>1</sup>

Raul Queiroz Feitosa <sup>1,2</sup>

Guilherme Lúcio Abelha Mota <sup>2</sup>

Kian Pakzad <sup>3</sup>

Maria Clara de Oliveira Costa <sup>1</sup>

<sup>1</sup> Pontifícia Universidade Católica do Rio de Janeiro – PUC-Rio  
Rua Marquês de São Vicente 225, Gávea, Rio de Janeiro, CEP: 22453-900, RJ, Brasil  
{gilson, raul, mclara}@ele.puc-rio.br

<sup>2</sup> Universidade do Estado do Rio de Janeiro – UERJ  
Rua São Francisco Xavier 524, Maracanã, Rio de Janeiro, CEP: 20550-900, RJ, Brasil  
guimota@gmail.com

<sup>3</sup> University of Hannover, Institute of Photogrammetry and GeoInformation  
1 Nienburger Street, Hannover D-30167, Germany  
pakzad@ipi.uni-hannover.de

**Abstract.** This paper introduces a new cascade multitemporal classification method based on Fuzzy Markov Chains. The method does not require knowledge of the true class at the earlier date; it uses instead the attributes of the image object being classified at both the later and the earlier date. The method combines the fuzzy, non temporal, classification of a geographical region in two points in time to provide a single unified result. A transformation law based on class transition possibilities projects the earlier classification to the later date before combining both results. Performance analysis was done with a sequence of three LANDSAT images from the central region of Brazil. The results showed that the performance gain depends highly on the accuracy of the monotemporal classifier at the earlier date. While the monotemporal approach attained an average class accuracy of approximately 55%, the multitemporal scheme achieved from 65% accuracy up to 95%, when knowledge of the true class at the earlier date was used.

**Palavras-chave:** cascade classifier, multitemporal analysis, fuzzy markov chain, classificador em cascata, análise multitemporal, cadeias de markov nebulosas.

## 1. Introdução

A maioria dos métodos automáticos para a interpretação de imagens multidata propostos até hoje seguem abordagens de “pós-classificação”. Estes métodos se baseiam em classificações independentes de cada imagem de uma série, cujos resultados são posteriormente comparados (Weismiller et al. 1977). Alternativas mais eficientes, chamadas de “classificação em cascata” (Swain 1978), usam toda a informação contida na seqüência de imagens, explorando a correlação temporal entre elas.

Diversos esquemas de classificação em cascata já foram propostos, incluindo métodos bayesianos (Serpico e Melgani 2000), redes neurais artificiais (Melgani et al. 2003; Bruzzone et al. 1999), bem como abordagens baseadas em múltiplos classificadores (e.g. Bruzzone et al. 2004). Apesar do crescente interesse por sistemas de classificação baseados em conhecimento estruturado através de regras nebulosas, são relativamente poucos os trabalhos encontrados na literatura sobre métodos de classificação em cascata baseados em regras nebulosas, em comparação com as demais abordagens.

Em Mota et al. (2007) e Costa et al. (2007) métodos multitemporais nebulosos foram propostos para aplicações de classificação de cobertura do solo. O primeiro método é, porém, restrito a aplicações em que a classe correta dos objetos a serem classificados é conhecida em

um momento anterior. Este artigo apresenta uma extensão do método proposto em Mota et al. (2007) – um novo método nebuloso de classificação multitemporal em cascata que oferece a opção de utilizar apenas atributos dos objetos no passado, ao invés da informação sobre suas classes verdadeiras. Relativamente à proposta de Costa et al.(2007) este artigo propõe uma nova parametrização do modelo multitemporal, que redundará num significativo aumento de desempenho, como mostra a avaliação experimental apresentada na Seção 4.

Neste novo método os resultados de duas classificações do mesmo segmento em duas datas diferentes são combinados em um único resultado consensual. Antes da fusão dos resultados, a classificação nebulosa na data anterior é submetida a uma transformação temporal que a projeta para a data posterior. Uma Cadeia de Markov Nebulosa é usada para modelar a transformação temporal.

Experimentos sobre uma seqüência de três imagens LANDSAT que recobrem um município no Centro-Oeste brasileiro demonstraram que o método multitemporal proposto pode aumentar significativamente o desempenho da classificação em relação à classificação monotemporal, desde que haja uma correlação temporal entre os dados das datas consideradas.

Este trabalho está organizado da seguinte maneira: a próxima seção contém uma breve introdução a Cadeias de Markov Nebulosas; na Seção 2 o método de classificação multitemporal proposto é apresentado; na Seção 3 são descritos experimentos de avaliação do método e respectivos resultados; por fim são apresentadas conclusões e propostas para trabalhos futuros.

## 2. Cadeias Nebulosas de Markov

Esta seção apresenta uma breve introdução ao conceito de Cadeias de Markov Nebulosas (CMN) no contexto de classificação multitemporal de imagens de sensoriamento remoto. Uma descrição mais geral e detalhada do conceito pode ser encontrada em Avrachenkov e Sanchez (2002).

Seja  $\Omega = \{\omega_1, \omega_2, \dots, \omega_n\}$  um conjunto de classes de uso ou cobertura do solo, uma relação nebulosa binária pode ser definida sobre o produto cartesiano  $\Omega \times \Omega$ , representada pela matriz de transição  $\mathbf{T} = \{\tau_{ij}\}$ . O símbolo  $\tau_{ij}$  denota a possibilidade de um objeto pertencer à classe  $\omega_i \in \Omega$  no instante  $t$  e à classe  $\omega_j \in \Omega$  no instante  $t+1$ , uma unidade arbitrária de tempo depois, sendo  $0 \leq \tau_{ij} \leq 1$  para  $i, j = 1, \dots, n$ . Isto pode ser representado graficamente por um diagrama de transição de classes (Figura 1), um grafo orientado ponderado cujos vértices correspondem às classes e as arestas às transições de classes possíveis entre  $t$  e  $t+1$ . O peso de cada aresta corresponde à possibilidade de transição  $\tau_{ij}$ . Para simplificar a representação, as arestas com  $\tau_{ij} = 0$  não são mostradas.

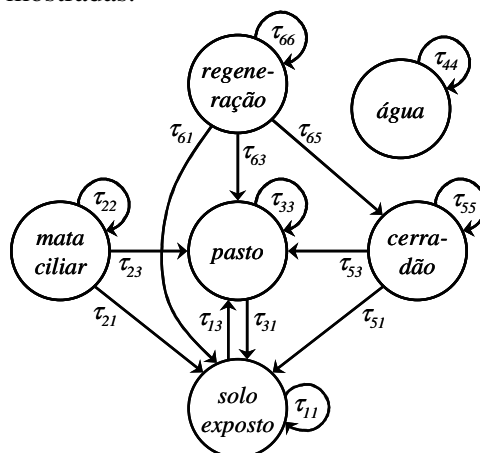


Figura 1. Diagrama de transição de classes com seis classes de cobertura do solo.

Assumimos que o vetor  ${}^t\boldsymbol{\alpha} = [{}^t\alpha_1, \dots, {}^t\alpha_n]$  com  $0 \leq {}^t\alpha_i \leq 1$  representa para um objeto em particular uma classificação nebulosa definida sobre  $\boldsymbol{\Omega}$  no tempo  $t$ , onde  ${}^t\alpha_i$  denota o grau de pertinência do objeto à classe  $\omega_i$ , para todo  $\omega_i \in \boldsymbol{\Omega}$ , no tempo  $t$ . Assumimos também que  ${}^t\alpha_i$  é uma função dos valores de atributos do objeto no tempo  $t$ .

Com base no vetor nebuloso  ${}^t\boldsymbol{\alpha}$  e na matriz de transição  $\mathbf{T}$ , o modelo de Cadeia de Markov Nebulosa estima os valores de pertinência às classes, representados pelo vetor  ${}^{t+1}\boldsymbol{\beta} = [{}^{t+1}\beta_1, \dots, {}^{t+1}\beta_n]$ , para o mesmo objeto, uma unidade de tempo depois, de acordo com a Equação 1, onde os símbolos  $\mathbf{T}$  e  $\perp$  representam respectivamente uma  $t$ -norm e uma  $s$ -norm.

$${}^{t+1}\beta_j = \perp_{i=1, \dots, n} \left\{ \mathbf{T}({}^t\alpha_i, \tau_{ij}) \right\}, \text{ para } i, j = 1, \dots, n \quad (1)$$

A lei de transição introduzida na Equação 1 pode ser expressa de forma mais compacta, como na equação abaixo.

$${}^{t+1}\boldsymbol{\beta} = {}^t\boldsymbol{\alpha} \circ \mathbf{T} \quad (2)$$

### 3. Método de Classificação Multitemporal

#### 3.1. Descrição do Problema

Sejam  ${}^t\mathbf{I}$  e  ${}^{t+1}\mathbf{I}$  duas imagens co-registradas recobrimdo a mesma região geográfica, adquiridas respectivamente nas datas  $t$  e  $t+1$ . Sejam  ${}^t\mathbf{x}$  e  ${}^{t+1}\mathbf{x}$  vetores compostos pelos valores das propriedades espectrais e espaciais do mesmo objeto visual – um segmento geometricamente coincidente – respectivamente em  ${}^t\mathbf{I}$  e  ${}^{t+1}\mathbf{I}$ . Assumimos também que  ${}^t\mathbf{w}$  e  ${}^{t+1}\mathbf{w}$  são vetores unitários  $n$ -dimensionais com a forma  $[0 \dots 1 \dots 0]$ , tendo “1” na posição  $i$  e “0” em todas as outras, indicando que o objeto pertence à classe  $\omega_i$  em uma data particular.

O problema de classificação multitemporal tratado neste trabalho consiste em encontrar o vetor  ${}^{t+1}\mathbf{w}$  para cada objeto visual, a partir dos vetores  ${}^t\mathbf{x}$  e  ${}^{t+1}\mathbf{x}$ , em outras palavras, o problema consiste em achar uma função  $\mathbf{M}$  com a seguinte forma:

$${}^{t+1}\mathbf{w} = \mathbf{M}({}^t\mathbf{x}, {}^{t+1}\mathbf{x}). \quad (3)$$

#### 3.2. Modelo Geral de Classificação

Nesta seção apresentamos um modelo de classificação para o problema descrito acima. Os temos monotemporal e multitemporal serão usados para designar classificadores cujas entradas estão associadas respectivamente a uma única ou a múltiplas datas. A saída do classificador multitemporal proposto pode ser considerada como uma fusão da saída de dois classificadores monotemporais, com representado na Figura 2.

Seja o primeiro classificador monotemporal representado por uma função  ${}^L\mathbf{C}$ , que calcula o grau de pertinência para o objeto sendo classificado no momento  $t+1$  baseado exclusivamente nas propriedades do objeto em  $t+1$ , extraídas da imagem  ${}^{t+1}\mathbf{I}$ . O classificador monotemporal  ${}^L\mathbf{C}$  produz um vetor  $n$ -dimensional  ${}^{t+1}\boldsymbol{\alpha} = [{}^{t+1}\alpha_1, {}^{t+1}\alpha_2, \dots, {}^{t+1}\alpha_n]$ , onde  ${}^{t+1}\alpha_i$  representa o grau de pertinência do objeto visual à classe  $\omega_i$ , para cada  $\omega_i \in \boldsymbol{\Omega}$ , e para ao menos um  $i$ ,  ${}^{t+1}\alpha_i \neq 0$  (Equação 4).

$${}^{t+1}\boldsymbol{\alpha} = {}^L\mathbf{C}({}^{t+1}\mathbf{x}) \quad (4)$$

Um segundo classificador monotemporal  ${}^E\mathbf{C}$  é aplicado ao vetor  ${}^t\mathbf{x}$ . De forma análoga ao primeiro classificador monotemporal, ele produz um vetor de pertinências  ${}^t\boldsymbol{\alpha}$ . Uma vez que  ${}^t\boldsymbol{\alpha}$  se refere à distribuição de pertinências a classes de cobertura do solo no tempo  $t$  e nosso objetivo é a classificação do objeto no tempo  $t+1$ , a lei de transição da CMN é aplicada para

inferir os graus de pertinência no tempo  $t+1$  baseado nas pertinências em  $t$ . Assim, se  $\mathbf{T}$  representa as transições de classe entre os tempos  $t$  e  $t+1$ , podemos estimar a classificação no tempo  $t+1$  através da seguinte fórmula:

$${}^{t+1}\boldsymbol{\beta} = {}^E\mathbf{C}({}^t\mathbf{x}) \circ \mathbf{T}. \quad (5)$$

Os dois vetores de pertinências  ${}^{t+1}\boldsymbol{\alpha}$  e  ${}^{t+1}\boldsymbol{\beta}$  são então combinados através de uma função de agregação  $\mathbf{F}$ , que gera o vetor de pertinências multitemporal  ${}^{t+1}\boldsymbol{\mu} = [{}^{t+1}\mu_1, \dots, {}^{t+1}\mu_n]$  (Equação 6).

$${}^{t+1}\boldsymbol{\mu} = \mathbf{F}({}^{t+1}\boldsymbol{\alpha}, {}^{t+1}\boldsymbol{\beta}) = \mathbf{F}[{}^L\mathbf{C}({}^{t+1}\mathbf{x}), {}^E\mathbf{C}({}^t\mathbf{x}) \circ \mathbf{T}] \quad (6)$$

O passo final é a *defuzzificação*, realizada por uma função  $\mathbf{H}$  que transforma o vetor de pertinências  ${}^{t+1}\boldsymbol{\mu}$  no vetor unitário  ${}^{t+1}\mathbf{w}$ . Combinando as equações anteriores, o classificador multitemporal  $\mathbf{M}$  é dado pela Equação 7 e representado graficamente na Figura 2.

$${}^{t+1}\mathbf{w} = \mathbf{M}({}^{t+1}\mathbf{x}, {}^t\mathbf{x}) = \mathbf{H}\{ \mathbf{F}[{}^L\mathbf{C}({}^{t+1}\mathbf{x}), {}^E\mathbf{C}({}^t\mathbf{x}) \circ \mathbf{T}] \} \quad (7)$$

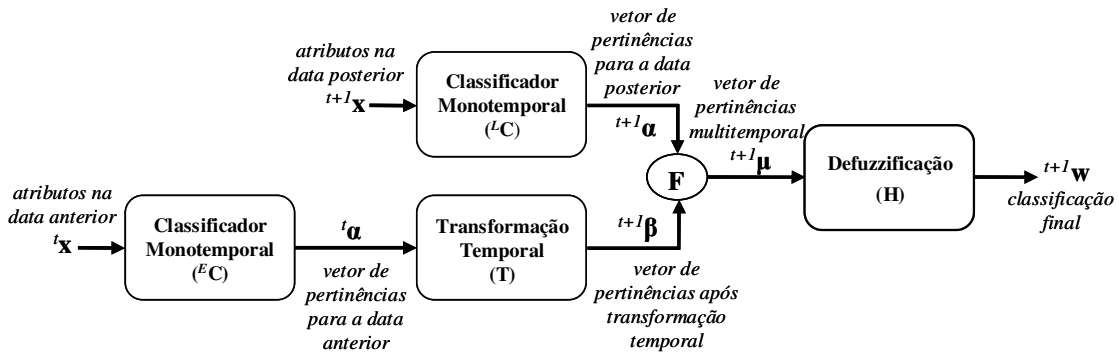


Figura 2. Modelo de classificação multitemporal em cascata proposto.

### 3.3. Particularização do Modelo

Existem várias alternativas para a função de defuzzificação  $\mathbf{H}$ , para a função de agregação  $\mathbf{F}$  e para a composição de *t-norm* e *s-norm* no operador “ $\circ$ ”, presentes no modelo definido pela Equação 7. Este artigo não investiga todas essas alternativas, mas se concentra em uma implementação específica do modelo, conforme descrito abaixo.

A etapa de defuzzificação é realizada pela função  $\mathbf{H}$  que seleciona a classe com maior grau de pertinência (Equação 8).

$$[w_1, \dots, w_n] = \mathbf{w} = \mathbf{H}(\boldsymbol{\mu}) = \mathbf{H}([\mu_1, \dots, \mu_n]), \text{ onde } w_j = \begin{cases} 1 & \text{para } \mu_j = \max\{\mu_1, \dots, \mu_n\} \\ 0 & \text{para } \mu_j \neq \max\{\mu_1, \dots, \mu_n\} \end{cases} \quad (8)$$

A função de agregação  $\mathbf{F}$  tem como saída o produto dos elementos correspondentes dos vetores de pertinência de entrada (Equação 9).

$${}^{t+1}\boldsymbol{\mu} = \mathbf{F}({}^{t+1}\boldsymbol{\alpha}, {}^{t+1}\boldsymbol{\beta}) = [{}^{t+1}\alpha_1 {}^{t+1}\beta_1, {}^{t+1}\alpha_2 {}^{t+1}\beta_2, \dots, {}^{t+1}\alpha_n {}^{t+1}\beta_n] \quad (9)$$

Finalmente, em relação ao operador “ $\circ$ ”, a operação *máximo* foi escolhida para a *s-norm* e o *produto* para a *t-norm* (vide Equação 1).

Assim, o modelo particular de classificação investigado neste trabalho seleciona para um objeto visual, no tempo  $t+1$ , a classe  $\omega_i \in \boldsymbol{\Omega}$ , cujo índice  $i$  corresponde ao da pertinência  ${}^{t+1}\mu_i$  na Equação 10.

$${}^{t+1}\mu_i = \max_k \left\{ \alpha_k \max_l \left( {}^t\alpha_l \tau_{lk} \right) \right\} = \max_{k,l} \left\{ \alpha_l \tau_{lk} {}^{t+1}\alpha_k \right\} \quad (10)$$

### 3.4. Estimação da Matriz de Transição

Neste trabalho as possibilidades de transição de classes  $\tau_{ij}$  foram definidas através de um procedimento supervisionado de otimização. O procedimento utilizou um conjunto de objetos visuais para os quais a classificação nos tempos  $t$  e  $t+1$  era conhecida. Para todos os objetos neste conjunto de treinamento foram calculadas as pertinências às classes de cobertura nos tempos  $t$  e  $t+1$ , através dos classificadores monotemporais  ${}^E\mathbf{C}$  e  ${}^L\mathbf{C}$ .

O procedimento estima então as possibilidades de transição de classes que maximizam o desempenho da classificação com base na *taxa de reconhecimento média por classe* no tempo  $t+1$ , valor definido como o percentual médio dos objetos de cada classe corretamente classificados pelo modelo no tempo  $t+1$ . Neste trabalho, foram usados Algoritmos Genéticos para este fim – técnica estocástica inspirada na teoria da evolução das espécies, aplicada em diversos problemas de otimização (Schmiedle et al. 2002).

O modelo de classificação proposto não impõe o uso de Algoritmos Genéticos nesta etapa, mas a técnica apresenta a vantagem de funcionar satisfatoriamente em casos em que a em função objetivo, que expressa a qualidade da solução, não atende às propriedades requeridas pela maioria dos métodos de otimização analíticos, como é o caso da taxa de reconhecimento média por classe, que é, por exemplo, claramente descontínua em relação aos elementos de  $\mathbf{T}$ .

O número máximo de possibilidades de transição é igual ao quadrado do número de classes ( $n^2$ ). Na maioria das aplicações este número pode ser reduzido fixando como zero a possibilidade de transições de classe impossíveis. Esta informação é um tipo de conhecimento prévio que pode ser obtido com um especialista na área alvo da aplicação. Em Costa et al. (2007) conhecimento prévio é usado para reduzir ainda mais o número de possibilidades de transição a estimar. Basicamente atribui-se o valor 1 à possibilidade de transição mais provável que parte de cada estado. No presente trabalho estimam-se as possibilidades de todas as transições possíveis.

## 4. Experimentos

Os experimentos descritos a seguir foram projetados para avaliar o método proposto, comparando seu resultado com o resultado da classificação monotemporal dos objetos no tempo posterior.

### 4.1. Descrição dos Dados

O conjunto de dados usado nos experimentos foi praticamente o mesmo que o usado em Mota et al. (2007). Neste artigo apresentamos apenas as principais características dos dados utilizados e das técnicas usadas no pré-processamento.

A área de teste situa-se no Município de Alcinoópolis, no Estado do Mato Grosso do Sul, região do Pantanal brasileiro. A região é coberta por uma única cena LANDSAT 7 (órbita/posição 224-073).

O método multitemporal proposto pode ser aplicado tanto para classificação baseada em pixels, como para a classificação baseada em segmentos, i.e. a imagem é inicialmente segmentada em regiões homogêneas, que são posteriormente classificadas levando em consideração suas propriedades espectrais, texturais e geométricas.

O procedimento de segmentação aplicado se baseia no Algoritmo Watershed (Vincent e Soille 1991) e é descrito em detalhes em Mota et al. (2007). As bandas 5, 4 e 3 de três imagens LANDSAT 7 foram usadas nos experimentos, adquiridas durante época de seca na região, nos anos de 1999 (5 de agosto), 2000 (7 de agosto) e 2001 (10 de agosto). Há duas

razões para usar apenas três bandas: primeiramente, a classificação de referência foi produzida através de interpretação visual usando apenas aquelas três bandas; além disso, a base de dados possui poucas amostras para algumas das classes, bandas adicionais aumentariam a demanda por amostras para o treinamento dos classificadores monotemporais.

As bandas de todas as três imagens foram empilhadas formando uma imagem artificial de nove bandas. Após a aplicação de um filtro para a eliminação de ruídos, o gradiente em cada banda foi calculado e o máximo para cada pixel, considerando todas as bandas, foi transferido para uma matriz bidimensional. Após a eliminação de valores de gradiente inferiores a um determinado limiar, o algoritmo Watershed foi aplicado sobre a matriz de gradientes e os segmentos considerados nos experimentos foram gerados. É importante notar que desta forma os objetos visuais em qualquer imagem apresentam exatamente a mesma posição e geometria.

A Tabela 1 descreve as classes de cobertura consideradas nos experimentos. Para medir o desempenho do método, uma classificação de referência para os objetos, em cada uma das três imagens, foi gerada por um especialista humano, usando como informação adicional uma videografia realizada em outubro de 2001, um mapeamento hidrográfico e o modelo digital de superfície da área.

Tabela 1. Classes de cobertura do solo.

Rótulo	Classe	Descrição	Número de Segmentos		
			1999	2000	2001
solo exposto ( $\omega_1$ )	Solo exposto	Solo degradado por erosão ou sendo preparado para cultivo.	93	76	51
mata ciliar ( $\omega_2$ )	Mata ciliar	Floresta densa ao longo de rios e córregos.	23	23	23
pasto ( $\omega_3$ )	Pasto	Pasto cultivado para atividade pecuária.	296	313	337
água ( $\omega_4$ )	Corpos d'água	Água aparente ou região pantanosa.	17	17	17
cerradão ( $\omega_5$ )	Cerradão	Formação florestal do bioma Cerrado – floresta do ponto de vista fisionômico que floristicamente se assemelha mais ao Cerrado sentido restrito.	75	75	76
regeneração ( $\omega_6$ )	Cerradão em regeneração	Área em regeneração, anteriormente usada como pasto.	6	6	6

## 4.2. Procedimento Experimental e Resultados

Nos experimentos realizados para avaliar a presente proposta, os classificadores monotemporais que compõem o classificador multitemporal são idênticos ao classificador descrito em Mota et al. (2007). Trata-se um classificador nebuloso beado nos dados espectrais, dados topográficos sobre a rede de drenagem.

O modelo multitemporal foi construído com base em entrevistas com um engenheiro agrônomo familiarizado com as mudanças de cobertura ao longo do tempo na área de teste. As transições possíveis dentro do espaço de *um ano* são apresentadas na Figura 1. Desconsiderando as transições impossíveis, no total 15 possibilidades de transição de classes tiveram que ser estimadas para cada par de datas considerado.

Nos experimentos, a taxa de reconhecimento média por classe foi usada como métrica para a estimação das possibilidades de transição. O conjunto de treinamento foi construído da seguinte forma. Os objetos visuais foram inicialmente separados, considerando as transições efetivamente ocorridas em um par de datas. Para estimar os parâmetros dos classificadores monotemporais, bem como das possibilidades de transição, aproximadamente 50% dos objetos em cada grupo foi selecionado aleatoriamente, compondo o conjunto de treinamento. Os restantes 50% de objetos foram usados para avaliar o desempenho do método.

A Tabela 2 mostra o desempenho alcançado tanto pelo classificador monotemporal, como pelo classificador multitemporal (duas colunas à direita) para cada par de datas. Os valores na Tabela 2 são médias, calculadas sobre os resultados de 100 execuções do experimento, cada

vez com uma nova seleção aleatória dos conjuntos de treinamento e teste. Nota-se que o método multitemporal obteve desempenho em média 10% melhor que o monotemporal.

Tabela 2. Taxa de reconhecimento médio por classe para a data posterior.

Datas		Reconhecimento médio por classe (%)	
Anterior	Posterior	Monotemporal	Multitemporal
1999	2000	55	63
2000	2001	55	65
1999	2001	55	65
<b>média</b>		55	65

Um experimento similar foi executado com o classificador monotemporal do tempo anterior substituído por um classificador ideal, o que corresponde a uma aplicação em que a classe dos objetos no passado é conhecida. Isto se encaixa em nosso modelo de classificação quando consideramos que a saída do classificador monotemporal para a data anterior é um vetor que indica a classe correta do objeto na data anterior, ou seja, que possui um valor “1” na posição referente à classe verdadeira, e valores “0” em todas as outras posições. É possível provar que isto é equivalente ao método proposto em Mota et al. (2007), o que não será feito aqui por limitações de espaço. Os resultados do experimento, para cada par de datas considerado é mostrado na Tabela 3.

Tabela 3. Taxa de reconhecimento médio por classe para a data posterior, usando um classificador monotemporal *ideal* para a data anterior.

Datas		Reconhecimento médio por classe (%)	
Anterior	Posterior	Monotemporal	Multitemporal
1999	2000	55	95
2000	2001	55	94
1999	2001	54	91
<b>Média</b>		55	93

Neste caso o esquema multitemporal apresentou um aumento notável de desempenho em relação ao classificador monotemporal – em média de 55% para 93%.

Comparando os resultados das tabelas 2 e 3 chega-se à intuitiva conclusão de que quanto mais preciso for o classificador monotemporal, maior é sua contribuição para a precisão da classificação multitemporal. De fato, métodos de classificação multitemporal em cascata são eficazes somente se existir uma correlação temporal entre os dados das diferentes épocas investigadas, e os classificadores monotemporais no esquema em cascata podem mascarar ou melhor evidenciar tal correlação. Isso explica a substancial diferença de desempenho para o classificador multitemporal, observada nas tabelas 2 e 3.

## 5. Conclusões

Um novo método de classificação multitemporal em cascata baseado em Cadeias de Markov Nebulosas foi proposto neste artigo. O método estende um método anterior, eliminando a necessidade de conhecer a classificação correta para todos os segmentos da imagem num instante no tempo anterior.

Uma vez que o método se propõe a explorar a correlação temporal entre dois conjuntos de dados, ele só trará benefícios para a classificação se tal correlação for significativa.

Considerando os atributos dos objetos geográficos em dois ao invés de um único ponto no tempo, o método explora um conjunto maior de informações no processo de classificação – basicamente o dobro de informações sobre cada objeto em relação às potencialmente usadas em um método monotemporal.

Ao aumentar a dimensionalidade do espaço de atributos, a demanda por amostras de treinamento para a estimação de parâmetros também aumenta. Em um método monotemporal

supervisionado, amostras que representam todas as  $n$  classes devem ser coletadas. Nesta abordagem multitemporal todas as possíveis transições de classes, da ordem de  $n^2$  no pior caso, devem ser apropriadamente representadas no conjunto de treinamento. Portanto, o processo de coletar amostras de treinamento torna-se mais laborioso, e o procedimento de treinamento como um todo se torna mais complexo. A análise experimental demonstrou que este esforço adicional pode ser recompensado com um expressivo aumento de desempenho, desde que uma correlação temporal significativa exista entre os conjuntos de dados das épocas consideradas. Neste sentido, a escolha dos classificadores monotemporais que participam do esquema multitemporal assume grande importância, uma vez que eles podem tornar mais evidente ou mascarar a correlação temporal entre os dados das diferentes épocas.

Diversas alternativas são consideradas para a continuação desta pesquisa, incluindo investigações de implementações alternativas do modelo geral de classificação, com diferentes funções de agregação e defuzzificação, componentes ( $s$ -norm e  $t$ -norm) da lei de transformação temporal e procedimentos de estimação dos parâmetros do modelo.

### **Agradecimento**

Ao CNPq, ao DLR (Alemanha) e à FAPERJ pelo apoio recebido para a realização desta pesquisa.

### **Referências Bibliográficas**

Avranchenkov, K. E.; Sanchez, E. Fuzzy Markov Chains and Decision-Making. **Fuzzy Optimization and Decision Making**, v. 1, n. 2, p. 143-159, Junho de 2002.

Bruzzone, L.; Prieto, D. F.; Serpico, S. B. A neural-statistical approach to multitemporal and multisource remote-sensing image classification. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 3, p. 1350-1359, 1999.

Bruzzone, L.; Cossu, R.; Vernazza, G. Detection of land-cover transitions by combining multivariate classifiers. **Pattern Recognition Letters**, v. 25, 1491-1500, 2004.

Costa, M. C. O.; Feitosa, R. Q.; Campos, V. O. Classificação multitemporal de imagens utilizando cadeias de Markov nebulosas. In: XIII SBSR - Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**. São José dos Campos: INPE, 2007. Artigos, p. 6453-6460, 2007.

Melgani, F.; Serpico, S. B.; Vernazza, G. Fusion of multitemporal contextual information by neural networks for multisensor remote sensing image classification. **Integrated Computer-Aided Engineering**, v. 10, n. 1, p. 81-90, 2003.

Mota, G. L. A.; Feitosa, R. Q.; Coutinho, H. L. C.; Liedtke, C. E.; Muller, S.; Pakzad, K.; Meirelles, M. S. P. Multitemporal fuzzy classification model based on class transition possibilities. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 62, p. 186-200, 2007.

Serpico, B., Melgani, F., 2000. A Fuzzy Spatio-Temporal Contextual Classifier for Remote Sensing Images. In: IGARSS-2000 IEEE-International Geoscience and Remote Sensing Symposium, Hawaii, USA, Julho de 2000. **Proceedings of the IGARSS-2000 IEEE-International Geoscience and Remote Sensing Symposium**, v. 5, p. 2438- 2440.

Schmiedle, F.; Drechsler, N.; Grosse, D.; Drechsler, R. Heuristic learning based on genetic programming. **Genetic Programming and Evolvable Machines**, v. 3, n. 4, p. 363-388, Dezembro de 2002.

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, Junho de 1991.

Weismiller, R. A.; Kristoof, S. J.; Scholz, D. K.; Anuta, P. E.; Momen, S. A. Change Detection in Coastal Zone Environments. **Photogrammetric Engineering and Remote Sensing**, v. 43, p. 1533-1539, 1977.