

Interpretação de imagens multitemporais de sensoriamento remoto com base na combinação de cadeias de Markov fuzzy

Andrei Olak Alves ¹
Guilherme Lucio Abelha Mota ¹
Gilson A. O. P. Costa ²
Raul Queiroz Feitosa ²

¹ Universidade do Estado do Rio de Janeiro - UERJ
Rua São Francisco Xavier 524, Maracanã, Rio de Janeiro, CEP: 20550-900, RJ, Brasil
kaageo@gmail.com guimota@ime.uerj.br

² 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}@ele.puc-rio.br

Abstract. Thematic maps produced through remotely sensed images interpretation are among the most important sources of information to the land use and land cover (LULC) dynamics comprehension. Such approach gives support to the analysis of the LULC development within a certain region of interest. Among the applications of such multitemporal studies are the evaluation of anthropic impact over the environment and deforestation monitoring. Despite being their scientific contributions notorious, most approaches are based on monotemporal classification of sequences of images that is, afterwards, compared in order to access the temporal dynamics. Therefore, one can clearly comprehend the limitation of such approaches, while taking into account the single time scope of the input attributes. Many of the research papers dedicated to the explicit temporal knowledge representation are recent. One important branch of the approaches available in the literature employs fuzzy Markov chains (FMC) in order to model a temporal transformation. One important issue left behind by the previous works corresponds to the combination of the estimated FMC in order to bring about a longer term one. The experimental results showed the superiority of such approach while compared to the monotemporal classification.

Palavras-chave: remote sensing, image interpretation, temporal knowledge, sensoriamento remoto, interpretação de imagens, conhecimento temporal.

1. Introdução

A contribuição científica dos trabalhos de classificação automática supervisionada de imagens no apoio aos estudos multitemporais deve ser reconhecida. Contudo, na maioria de tais abordagens, simplesmente, imagens adquiridas em diferentes datas são individualmente classificadas, procedimento denominado classificação monotemporal. Em seguida, os mapas temáticos produzidos são analisados em um contexto multitemporal na avaliação da dinâmica do uso e da cobertura da terra.

Como alternativa à classificação monotemporal, vêm emergindo métodos de classificação multitemporal. Em linhas gerais, a classificação multitemporal se vale de informações obtidas no passado para facilitar e melhorar a qualidade da classificação automática da imagem sob análise. Pode-se compreender a superioridade da classificação multitemporal frente à classificação monotemporal pelo fato de primeira utilizar um conjunto mais rico de atributos.

Um ponto comum dos métodos de classificação multitemporal presentes na literatura, Bruzzone (2000), Jeon e Landgrebe (1992), Jeon e Landgrebe (1999), Aach e Kaup (1995), Solberg et al. (1996), Bruzzone et al. (1999), Bruzzone e Cossu (2002), Bruzzone et al. (2004), reside na intenção de valer-se de toda a informação contida na sequência de imagens com o intuito de explorar a correlação entre as imagens. No entanto, tais iniciativas, em sua maioria, não se utilizam de um modelo explícito de conhecimento temporal durante o processo de classificação.

As pesquisas que modelam explicitamente a dinâmica temporal para classificação automática de séries de imagens multitemporais são recentes. Alguns trabalhos anteriores, Campos et al. (2005), Mota et al. (2007), Feitosa et al. (2009), Costa et al. (2009) empregaram Cadeias de Markov Fuzzy (CMF) para a representação do conhecimento temporal. O modelo em proposto em tais trabalhos deu origem a uma abordagem em cascata capaz de capturar a correlação existente entre a dinâmica temporal e dados espectrais.

No entanto, as pesquisas anteriores relacionadas à classificação multitemporal em cascata com o uso de CMF apresentaram como limitação o uso de uma pequena série temporal de imagens. Este fato, por sua vez, impossibilitou uma investigação mais detalhada sobre a extrapolação do conhecimento temporal – representado explicitamente pela matriz de possibilidades de transição de estados – adquirido para um curto intervalo de tempo, para intervalos maiores. Tal investigação representa o objetivo central do presente trabalho.

Para facilitar o entendimento dos métodos utilizados, este trabalho foi organizado da seguinte forma: a Seção 2 apresenta uma breve introdução sobre a modelagem do conhecimento temporal com o uso de Cadeias de Markov Fuzzy; a Seção 3 apresenta o método de classificação multitemporal e o método de extrapolação de transformações temporais; na Seção 4 são descritos experimentos de avaliação do método e respectivos resultados; por fim, são apresentadas conclusões e propostas para trabalhos futuros.

2. Modelagem do Conhecimento Temporal

O método de classificação multitemporal empregado neste trabalho faz uso de Cadeias de Markov Fuzzy (CMF) para modelar o conhecimento temporal. Em linhas gerais, cadeias de Markov podem ser descritas como uma sequência temporal de variáveis aleatórias que correspondem aos estados de um determinado sistema, de tal forma que o estado da cadeia em um determinado tempo depende apenas do estado no tempo anterior (Ching e Ng, 2006). A grande diferença entre uma cadeia de Markov convencional e uma CMF está nos conjuntos de valores que as variáveis podem assumir. No caso das CMF ao invés de probabilidades são empregados conjuntos de valores nebulosos. Assim, a CMF dá suporte ao tratamento possibilístico, se tornando mais flexível que o tratamento probabilístico das cadeias de Markov. O leitor interessado numa descrição mais geral e detalhada do conceito de CMF pode recorrer a Avrachenkov e Sanchez (2002).

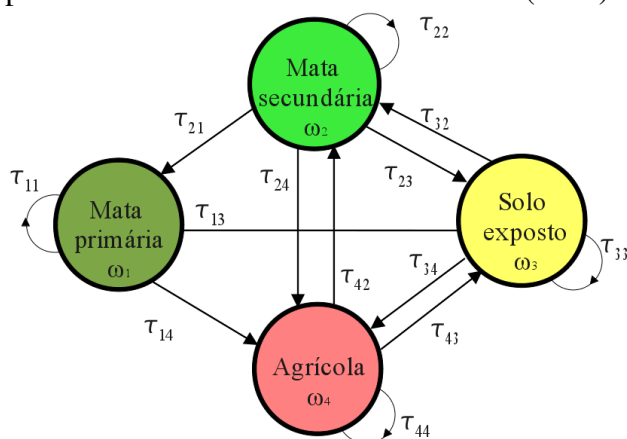


Figura 1. Diagrama de transição de classes.

O diagrama de transição apresentado na Figura 1 é uma representação gráfica da matriz de possibilidades de transição de uma CMF para um determinado intervalo de tempo e um conjunto específico de estados.

Os estados da CMF correspondem a um conjunto de classes de uso/cobertura do solo $\Omega = \{\omega_1, \omega_2, \dots, \omega_c\}$, onde c corresponde ao número de classes. O valor de c não varia ao longo

do tempo. A matriz de possibilidades de transição ${}^t\mathbf{T} = \{\tau_{ij}\}$ corresponde a uma relação nebulosa binária definida sobre o produto cartesiano $\Omega \times \Omega$. O símbolo τ_{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 posterior, sendo $0 \leq \tau_{ij} \leq 1$ para $i, j = 1, \dots, c$. Esta relação pode ser representada graficamente pelo *diagrama de transição de classes*, que, conforme apresenta a Figura 1, é um grafo orientado ponderado. Neste grafo, os 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 τ_{ij} . Para simplificar a representação, as arestas com $\tau_{ij} = 0$ não são mostradas.

Tomando como base o vetor nebuloso ${}^t\boldsymbol{\alpha}$ e a matriz de transição ${}^t\mathbf{T}$, o modelo de Cadeia de Markov Fuzzy pode estimar para um dado objeto, através de sua lei de transição (Equação 1) os valores de pertinência às classes, ${}^{t+1}\boldsymbol{\beta} = [{}^{t+1}\beta_1, \dots, {}^{t+1}\beta_c]$, para uma unidade de tempo posterior.

$${}^{t+1}\beta_j = \perp_{i \in [1, c]} \left[\top({}^t\alpha_i, \tau_{ij}) \right] \quad \forall i, j \in [1, c] \quad (1)$$

Os símbolos \top e \perp na Equação 1 representam respectivamente uma *t-norm* e uma *s-norm*. Neste trabalho, conforme indicado na Seção 4.2 a *t-norm* selecionada foi o operador *máximo* e a *s-norm*, o operador *mínimo*. A lei de transição introduzida na Equação 1 pode ser expressa de forma mais compacta, como na equação abaixo.

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

3. Método de Classificação Multitemporal

O procedimento de classificação é apresentado na Figura 2. De maneira simplificada, o processo consiste na fusão de dois conjuntos de dados: a) o vetor de valores de pertinência fuzzy ${}^{t+k}\boldsymbol{\mu}$, fornecidas por um classificador monotemporal e calculadas com base em um vetor de atributos ${}^{t+k}\mathbf{x}$ do objeto, medidos no instante de tempo presente, simbolizado por $t+k$; e b) o vetor de valores de pertinência temporais ${}^{t+k}\boldsymbol{\beta}$, obtido pela aplicação da transformação temporal (Equação 1) ao vetor crisp ${}^t\mathbf{w}$, que representa a classificação num instante passado, simbolizado por t . O vetor ${}^t\mathbf{w}$ é um vetor unitário n -dimensional 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 ω_i no instante t .

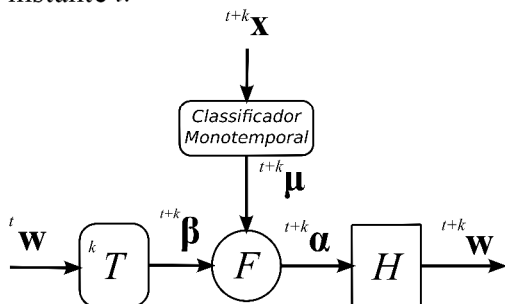


Figura 2. Método de classificação multitemporal

Conforme pode ser observado na Figura 2, o vetor de pertinências ${}^{t+k}\boldsymbol{\alpha}$ é o resultado da fusão de ${}^{t+k}\boldsymbol{\mu}$ e ${}^{t+k}\boldsymbol{\beta}$, realizada pela função F . O defuzzificador H fornece o vetor ${}^{t+k}\mathbf{w}$, que representa a classificação de um objeto no instante de tempo presente.

3.2 Treinamento do Classificador

A geração do vetor de pertinências temporais ${}^{t+k}\boldsymbol{\beta}$ requer a estimação das pertinências que compõem a matriz de transição ${}^k\mathbf{T}$. Os valores das possibilidades de transição de classes τ_{ij} são

na presente proposta, estimados através de um procedimento de treinamento supervisionado efetuado por um algoritmo genético (AG). Basicamente, algoritmo genético é um método de otimização inspirado na teoria Darwiniana da evolução das espécies. Neste procedimento, uma função objetivo realiza o papel do meio no qual os indivíduos da população estão inseridos. Quanto mais apto for um indivíduo, mais vezes ele é selecionado para levar seu material genético para a próxima geração.

A função de avaliação, no presente trabalho, analisa a qualidade da classificação proporcionada por um dado indivíduo em um conjunto de objetos para os quais a classificação nos tempos t e $t+k$ é conhecida. Após um dado número de gerações, o melhor indivíduo da população é selecionado. Os AGs são inspirados na idéia de que, a cada geração, a população tende a evoluir, ficando cada vez mais apta a sobreviver à seleção natural.

3.3 Método de Extrapolação das Transformações Temporais

O método de Extrapolação das Transformações Temporais consiste em combinar k vezes a matriz de transição 1T , calculada para os instantes t e $t+1$, com o objetivo de se obter uma matriz combinada kT . A operação de combinação, simbolizada por \circ , corresponde ao produto de matrizes substituindo-se o produto e a soma dos escalares por τ e a soma por \perp , respectivamente operadores t -norm e s -norm. Esta operação fornece a matriz de transição estimada conforme expressa a Equação 3, a seguir.

$$\begin{aligned} {}^2T &= {}^1T \circ {}^1T \\ {}^kT &= ({}^{k-1}T) \circ {}^1T \end{aligned} \quad (3)$$

4. Análise Experimental

Os experimentos descritos a seguir visam à avaliação preliminar da qualidade da classificação multitemporal produzida por kT , estimado a partir de 1T (conforme descrito na Seção 3.3.). No conjunto de dados de referência empregados nos experimentos, 1T corresponde a um intervalo de 5 anos e kT a intervalos de 10, 15 e 20 anos.

4.1 Área de Estudo e Base de Dados

A área de estudo corresponde a um remanescente florestal situado a oeste do município de Londrina, estado do Paraná, que inclui o Parque Estadual Mata dos Godoy (PEMG). Este remanescente apresentado na Figura 3 é uma Área de Proteção Ambiental circundada por áreas ocupadas por agricultura e pecuária, e sujeito as pressões antrópicas.

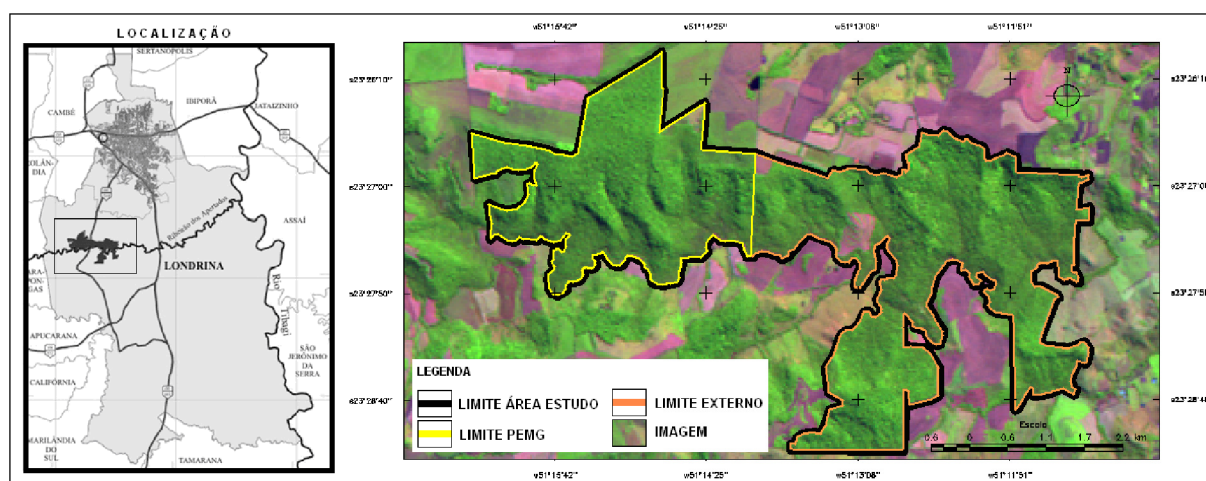


Figura 3. Área de Estudo.

A série temporal compreende cinco imagens Landsat 5 TM, órbita/ponto 222/076, bandas 3, 4 e 5, com intervalo temporal de cinco anos, com datas de: 03/08/1989; 16/07/1994; 14/07/1999; 27/07/2004; e 22/05/2009.

As imagens foram segmentadas no software SPRING 5.1.4, utilizando o algoritmo de segmentação por crescimento de regiões. O procedimento foi o mesmo utilizado em (Mota et al., 2007; Feitosa et al., 2009; e Costa et al., 2009). Todas as imagens foram empilhadas formando uma única imagem multibanda multitemporal. Em seguida, aplicou-se o algoritmo de segmentação sobre a imagem formada no passo anterior. Este procedimento permite eliminar os problemas relacionados aos ajustes de borda de diferentes segmentos em imagens de datas distintas, já que os segmentos gerados para os diferentes instantes de tempo (a serem posteriormente classificados) são idênticos. A classificação de referência dos segmentos, para cada um dos cinco instantes de tempo, foi gerada por um especialista humano, usando como informação adicional o plano de manejo do PEMG e imagens de maior resolução espectral (adquiridas partir do ano 2000). As classes da legenda e o número de segmentos em cada data são apresentados na Tabela 1.

Tabela 1. Classes de cobertura da terra.

Classes	Descrição	Números de Segmentos				
		1989	1994	1999	2004	2009
Vegetação Primária (ω_1)	Vegetação densa, que preserva as características originais ou que está regenerada a tal ponto que não é possível distinguir entre regeneração e vegetação primária.	470	479	513	532	551
Vegetação Secundária (ω_2)	Vegetação menos densa do que a vegetação primária, geralmente em processo de regeneração.	97	91	83	78	71
Solo Exposto (ω_3)	Solo degradado por erosão ou sendo preparado para cultivo, ou vegetação ripária.	83	80	54	24	9
Agropastoril (ω_4)	Atividade agrícola ou pasto cultivado para atividade pecuária.	0	0	0	16	19

4.2 Implementação do protótipo experimental

Os métodos de classificação multitemporal e monotemporal foram implementados no software Matlab. Para classificação monotemporal, foi utilizado um classificador de regiões que utiliza o método da distância de Bhattacharya (Comaniciu et al., 2000), baseado exclusivamente em atributos espectrais.

Com base na série temporal escolhida, nas características da área estudada e nas classes de uso e cobertura da terra, foram calculadas matrizes de transição para intervalos de 5 anos.

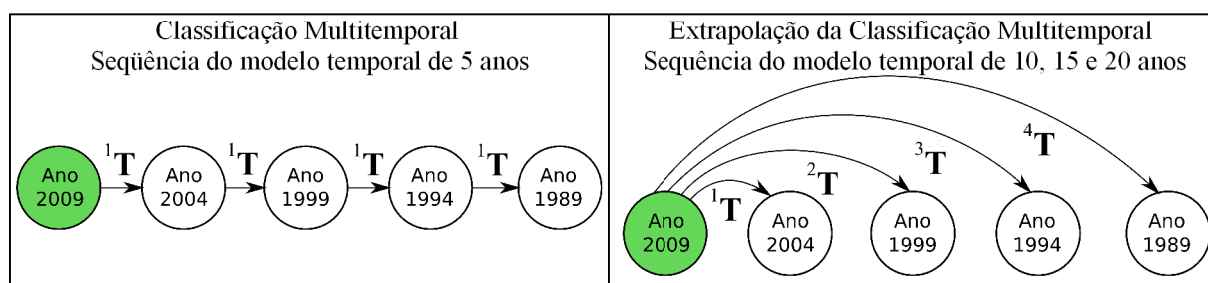


Figura 4. Sequência do modelo temporal de 5 anos e da extrapolação.

A inexistência, nos anos de 1989, 1994 e 1999, de objetos da classe “Agropastoril” poderia prejudicar a estimação da matriz de transição que será posteriormente objeto do procedimento de extrapolação (Seção 3.3). Para evitar este inconveniente, a sequência temporal utilizada nos experimentos foi invertida. Deve-se mencionar a inexistência de restrições teóricas para esta inversão. A Figura 4 apresenta a sequência adotada no

experimento, onde 1T se refere ao modelo temporal de 5 anos, e 2T , 3T e 4T aos modelos de 10, 15 e 20 anos, respectivamente.

Nos experimentos, os operadores *s-norm* e *t-norm* empregados na combinação das CMF foram, respectivamente, o *máximo* e o *mínimo*. O treinamento do classificador monotemporal foi realizado a partir de sorteios aleatórios, sendo selecionados 50% dos segmentos para o treinamento, tomando como base os objetos de referência, classificados anteriormente pelo fotointérprete. Os restantes 50% de objetos foram usados para avaliar o desempenho do método. Foram realizados 25 sorteios do conjunto de treinamento e de validação. Para cada sorteio, o Algoritmo Genético foi executado cinco vezes, sendo usado como função de avaliação o índice Kappa da classificação do conjunto de teste. Os dados apresentados na análise a seguir correspondem aos melhores índices de treinamento obtidos nestas tentativas.

4.3 Resultados

Devido à seqüência de classificação apresentada na Figura 4, a análise dos resultados também foi feita de ordem inversa, partido-se dos anos de 2009 até 1989. É importante ressaltar que, como o modelo temporal utiliza estado da cobertura do solo na instância anterior, a primeira classificação multitemporal a ser apresentada é a de 2004.

Na Tabela 2, pode-se, para cada ano analisado, observar o desempenho (índice Kappa) alcançado pelo classificador multitemporal e compará-lo ao do classificador monotemporal. Pode ser notado que o desempenho da classificação multitemporal, mesmo para a extrapolação, apresentou ganho expressivo em relação a classificação monotemporal.

Tabela 2. Resultados de classificação para a série analisada.

Classificação	Índice Kappa				Média de Classificação	Ganho médio em relação classificação Monotemporal
	2004	1999	1994	1989		
Monotemporal	0,53	0,53	0,53	0,54	0,53	-
Multitemporal - 1T	0,82	0,76	0,79	0,79	0,79	0,26
Multitemporal estimado kT	-	0,68 (2T)	0,60 (3T)	0,62 (4T)	0,63	0,1

O ganho médio no índice Kappa da classificação multitemporal em relação à monotemporal, utilizando o modelo temporal de 5 anos, foi de 0,26, enquanto o ganho utilizando CMF estimada por extrapolação foi de 0,10. Percebe-se claramente a superioridade do método de classificação multitemporal frente a classificador monotemporal. No caso específico das CMF estimadas, é esperado que à medida que a distância temporal aumente, o desempenho da classificação decaia. Esta pode ser uma razão para as diferenças entre o resultado em 1999 e nos anos de 1994 e 1989.

Mesmo com a irregularidade verificada nas classificações multitemporais, o ganho obtido ainda foi bastante significativo em relação à monotemporal. Contudo é necessária a análise do desempenho para cada classe. Estes resultados são apresentados na Figura 5. A omissão da classe “Agropastoril” se deve ao fato de não haver segmentos pertencentes a esta classe na área de estudo nos anos de 1999, 1994 e 1989.

Na Figura 5, pode-se observar que o desempenho da extrapolação para a classe “Vegetação Primária” foi sempre e consistentemente superior ao da classificação monotemporal. Ainda para esta classe, os resultados da classificação multitemporal e da classificação multitemporal a partir de CMF estimadas foram compatíveis.

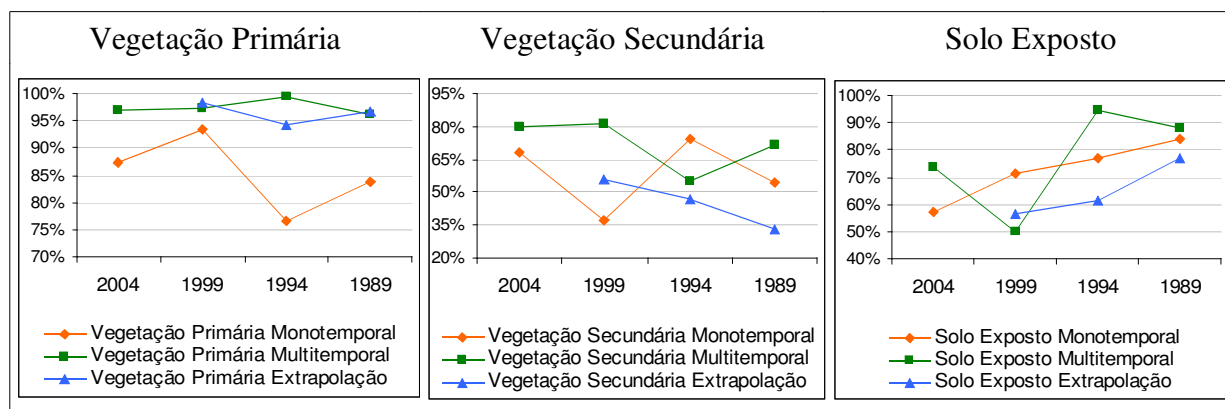


Figura 5. Representação das taxas de classificação por classe.

No caso da classe “Vegetação Secundária”, a CMF estimada de 10 anos (resultado de 1999) permite desempenho superior ao da classificação monotemporal. Contudo para 1994 e 1989, respectivamente 15 e 20 anos o desempenho da classificação multitemporal com base na extrapolação da matriz de transição foi inferior ao da classificação monotemporal. Ao verificar as características espectrais da imagem classificada, observa-se que as regiões de “Vegetação Secundária” sofreram grandes alterações no período histórico, passando de uma região quase totalmente de “Solo Exposto” em 1989 para “Vegetação Primária” em 2009. Com isso, no momento da modelagem do conhecimento temporal para o intervalo de 5 anos (2009→2004), existe uma grande semelhança espectral entre as classes “Vegetação Primária” e “Vegetação Secundária”, o que gera uma confusão entre as classes e que, conseqüentemente, é transportado para os classificadores em toda a série temporal.

A classe “Solo Exposto”, por sua vez, apresenta baixo desempenho com o uso da classificação multitemporal. No que diz respeito à combinação de CMF, o desempenho é ainda mais pobre, pois ocorre perda nos anos de 1999, 1994 e 1989. O motivo é semelhante ao apresentado na análise da classe “Vegetação Secundária”, no momento da geração do conhecimento temporal (2009→2004) praticamente não ocorre a classe “Solo Exposto”.

4.2 Conclusões

O objetivo deste trabalho foi dar início à análise de um aspecto não explorado da classificação multitemporal em cascata apresentado em trabalhos anteriores (Mota et al., 2007; Feitosa et al., 2009; Costa et al. 2009). Trata-se da utilização da combinação de CMF de intervalo de tempo curto como forma de estimação de CMF de intervalo longo.

Para um modelo de transformação temporal de 5 anos (${}^1T_{2009\rightarrow 2004}$), o método de classificação multitemporal melhorou o resultado das imagens classificadas em 0,26 quando comparado com um classificador monotemporal. No momento em que se extrapolou modelo de transformação temporal de 5 anos para classificar as imagens de 10, 15 e 20 anos, o classificador apresentou, ainda, um ganho 0,10 em relação a classificação monotemporal.

Verifica-se, assim, o potencial do método de estimação proposto. Outro aspecto que pode ser destacado diz respeito ao fato do método poder ser utilizado em regiões com características geográficas distintas, uma vez que ele foi aplicado a uma região geográfica diferente da utilizada em pesquisas anteriores. Neste trabalho, a CMF para o intervalo de 5 anos utilizada na estimação das CMF para 10, 15 e 20 anos foi obtida para os pares de datas 2009→2004. Na sequência da pesquisa, 1T será estimada para outros pares de datas.

5 Agradecimentos

Os autores gostariam de manifestar sua gratidão à Faperj pelo apoio financeiro fornecido ao projeto IOBAC, contexto no qual está inserida a presente pesquisa.

6 Referências Bibliográficas

Aach, T., Kaup, A., Bayesian algorithms for adaptive change detection in image sequences using Markov random fields. In: **Signal Processing: Image Communication** 7 (2), 1995, p. 147–160.

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.; Cossu, R.; Prieto, D. Combining Parametric and Nonparametric Classifiers for an Unsupervised Updating of Land-Cover Maps- Multiple Classifier Systems - Springer J. Kittler and F. Roli (Eds.): MCS 2000, LNCS 1857, © Springer-Verlag Berlin Heidelberg, pp. 290-299, 2000.

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 multirate classifiers. **Pattern Recognition Letters**, v. 25, 1491-1500, 2004.

Bruzzone, L., Cossu, R., 2002. A multiple-cascade-classifier system for a robust and partially unsupervised updating of land-cover Maps. **IEEE Transactions on Geoscience and Remote Sensing** 40 (9), 1984–1996.

Campos, V. de O. ; Feitosa, R. Q. ; Mota, G. L. A. ; Pacheco, M. A. C ; Coutinho, H. L. da C. . Um Método para Modelagem do Conhecimento Multitemporal no Processo de Classificação Automática de Imagens de Sensores Remotos. **Revista Brasileira de Cartografia**, v. 57, n. 1, p. 28-35, 2005.

Ching, W.; Ng, M. K. **Markov Chains: Models, Algorithms and Applications**. New York: Springer, 2006.

Comaniciu, D.; Ramesh, V.; Meer P. Real-Time Tracking of Non-Rigid Objects using Mean Shift. **IEEE Conference on Computer Vision and Pattern Recognition**, Vol. 2, p.142–149, 2000.

Costa, Gilson A. O. ; Feitosa, Raul Q. ; MOTA, G. L. A. ; Pakzad, Kian ; Costa, Maria C.O.. Um Método de Classificação Multitemporal em Cascata de Imagens de Sensoriamento Remoto. In: **SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**, XIV, Natal. Anais... Salvador: INPE, p. 1291-1298, 2009.

Feitosa, Raul Q. ; Costa, Gilson A.O.P. ; MOTA, G. L. A. ; Pakzad, Kian ; Costa, Maria C.O. . Cascade multitemporal classification based on fuzzy Markov chains. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, p. 159-170, 2009.

Jeon, B., Landgrebe, D.A.. Classification with spatio-temporal interpixel class dependency contexts. **IEEE Transactions on Geoscience and Remote Sensing** 30 (4), p. 663–672, 1992.

Jeon, B., Landgrebe, D.A.. Decision fusion approach for multitemporal classification. **IEEE Transactions on Geoscience and Remote Sensing** 37 (3), p.1227–1233, 1999.

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.

Solberg, H.S., Taxt, T., Jain, A.K.. A Markov random field model for classification of multisource satellite imagery. **IEEE Transactions on Geoscience and Remote Sensing** 34 (1), p. 100–113, 1996.