Andrei Olak Alves

Interpretação de imagens multitemporais de sensoriamento remoto

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia da Computação, da Universidade do Estado do Rio de Janeio. Area de concentração: Geomática.

Orientador: Prof. Dr. Guilherme Lucio Abelha Mota

Coorientador: Prof. Dr. Gilson Alexandre Ostwald Pedro da Costa

Rio de Janeiro

2011

CATALOGAÇÃO NA FONTE

UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

A 474 Alves, Andrei Olak.
Interpretação de imagens multitemporais de sensoriamento remoto / Andrei Olak Alves. – 2011.
98f.

Orientador: Guilherme Lucio Abelha Mota.
Coorientador: Gilson Alexandre Ostwald Pedro da Costa.
Dissertação (Mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia.

1. Engenharia de Computação. 2. Sensoriamento remoto – Teses. I. Mota, Guilherme Lucio Abelha. II. Universidade do Estado do Rio de Janeiro. III. Título.

CDU 004.41:528.87

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta tese, desde que citada a fonte.

Assinatura

Data

Andrei Olak Alves

Interpretação de imagens multitemporais de sensoriamento remoto

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia da Computação, da Universidade do Estado do Rio de Janeio. Área de concentração: Geomática.

Aprovada em 1 de junho de 2011.

Banca Examinadora:

_____

Prof. Dr. Guilherme Lucio Abelha Mota (Orientador)
Instituto de Matemática e Estatística da UERJ

_____

Prof. Dr. Gilson Alexandre Ostwald Pedro da Costa (Coorientador)
Pontifícia Universidade Católica do Rio de Janeiro

_____

Prof. Dr. Raúl Sánchez Vicens
Universidade Federal Fluminense

_____

Prof. Dr. Raul Queiroz Feitosa
Pontifícia Universidade Católica do Rio de Janeiro

Rio de Janeiro

2011

DEDICATÓRIA

Ao Rei dos reis e Senhor dos senhores, pela Vida, Fé, Esperança e Amor que me concedeu! À minha querida esposa e ao nosso *futuro herdeiro*, pelo amor e felicidade que me proporcionam e pela paciência e compreensão nos momentos difíceis. Aos meus pais e à toda minha família, pelas orações, incentivos e ajuda. Ao meu orientador Guilherme, pela amizade e pelas "milhares" de horas de trabalho *sem descanso*, com o objetivo de elaborarmos uma boa dissertação.

AGRADECIMENTOS

Agradeço a Deus, por todas as bençãos e, principalmente, por eu estar concluindo mais uma etapa na minha vida.

A minha esposa, meus pais, meus sogros e toda a minha família, por todo auxílio dado no período do mestrado.

A K2 Sistemas, em especial ao amigo Carlos Henrique Levy, pela compreensão nestes dois anos de “tempo escasso”.

Ao Prof. Dr. Guilherme Lucio Abelha Mota, pela ajuda desde o primeiro dia de mestrado, pela amizade e pela competência nas orientações.

Ao Prof. Dr. Gilson Alexandre Ostwald Pedro da Costa pela coorientação e ao Prof. Dr. Raul Queiroz Feitosa, pelas contribuições feitas para este trabalho.

A todas as pessoas que serviram de incentivo e que me auxiliaram no decorrer da minha vida pessoal e profissional, em especial aos amigos(as) Osvaldo Coelho Pereira Neto, Mirian Vizintim Fernandes Barros e Rosely Sampaio Archela.

A FAPERJ, pelo auxílio de bolsa, e ao projeto IOBAC – Interpretação Orientada a Objetos e Baseada em Conhecimento de dados obtidos por Sensores Remotos, que proporcionou recursos para viabilizar esta dissertação.

RESUMO

ALVES, Andrei Olak. *Interpretação de imagens multitemporais de sensoriamento remoto*. 2011. 98 f. Dissertação (Mestrado em Engenharia da Computação) - Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2011.

Estudos multitemporais de dados de sensoriamento remoto dedicam-se ao mapeamento temático de uso da terra em diferentes instâncias de tempo com o objetivo de identificar as mudanças ocorridas em uma região em determinado período. Em sua maioria, os trabalhos de classificação automática supervisionada de imagens de sensoriamento remoto não utilizam um modelo de transformação temporal no processo de classificação. Pesquisas realizadas na última década abriram um importante precedente ao comprovarem que a utilização de um modelo de conhecimento sobre a dinâmica da região (modelo de transformação temporal), baseado em Cadeias de Markov Fuzzy (CMF), possibilita resultados superiores aos produzidos pelos classificadores supervisionados monotemporais. Desta forma, o presente trabalho enfoca um dos aspectos desta abordagem pouco investigados: a combinação de CMF de intervalos de tempo curtos para classificar imagens de períodos longos. A área de estudo utilizada nos experimentos é um remanescente florestal situado no município de Londrina-PR e que abrange todo o limite do Parque Estadual Mata dos Godoy. Como dados de entrada, são utilizadas cinco imagens do satélite Landsat 5 TM com intervalo temporal de cinco anos. De uma forma geral, verificou-se, a partir dos resultados experimentais, que o uso das Cadeias de Markov Fuzzy contribuiu significativamente para a melhoria do desempenho do processo de classificação automática em imagens orbitais multitemporais, quando comparado com uma classificação monotemporal. Ainda, pôde-se observar que as classificações com base em matrizes estimadas para períodos curtos sempre apresentaram resultados superiores aos das classificações com base em matrizes estimadas para períodos longos. Também, que a superioridade da estimação direta frente à extrapolação se reduz com o aumento da distância temporal. Os resultados do presente trabalho poderão servir de motivação para a criação de sistemas automáticos de classificação de imagens multitemporais. O potencial de sua aplicação se justifica pela aceleração do processo de monitoramento do uso e cobertura da terra, considerando a melhoria obtida frente a classificações supervisionadas tradicionais.

Palavras-chave: Sensoriamento Remoto, Interpretação de Imagens Multitemporais, Cadeias de Markov Fuzzy, Classificação Automática Supervisionada.

ABSTRACT

Multitemporal remote sensing data analysis is concerned to the thematic mapping of land use in different instances of time, aiming to identify changes in land cover/use in such period. Most multitemporal studies in the literature, while producing the thematic mapping, merely perform separate supervised automatic classifications of the remote sensing images. That is the so-called monotemporal approach, in which the classification process do not take advantage of the temporal dynamics knowledge. Recent essays conducted over the past decade had indicated that the use of a model of knowledge about the dynamics of the region (temporal transformation model) based on Fuzzy Markov Chains (FMC) provides superior results than the supervised monotemporal classifiers. This master's dissertation focuses on one aspect of such approach still not enough investigated: the combination of FMC for short time intervals to classify images of longer periods. Herein, the study area is a forest remnant in the municipality of Londrina, Paraná, in south of Brazil, which encompasses the borders of the Mata dos Godoy State Park. The database is composed by five Landsat 5 TM images, each one acquired five years after the previous. The experiments showed that the use of Fuzzy Markov Chains to model the temporal dynamics can improve the performance of the classification process, while compared to the conventional monotemporal approach. Besides, it could be observed that the more recent is the past information the better is the classification performance. Other important aspect that could be noticed was the reduction of the superiority of direct estimation of FMC over its extrapolation, as well temporal distance increases. This approach can contribute to the increment of the degree of automation of multitemporal images sequence classification. Considering the improvement in the classification performance, its application could also speed up the land use / cover monitoring.

Keywords: Remote Sensing, Interpretation of multitemporal images, Fuzzy Markov Chains, Automatic Supervised Classification.

LISTA DE FIGURAS

Figura 1 – Digrama de Transição de Estados.....26
Figura 2 – Método de classificação multitemporal.....27
Figura 3 – Área de Estudo.....33
Figura 4 – Imagem de 1989.....35
Figura 5 – Imagem de 1994.....36
Figura 6 – Imagem de 1999.....36
Figura 7 – Imagem de 2004.....37
Figura 8 – Imagem de 2009.....37
Figura 9 – Mapas temáticos de referência de uso e cobertura da terra.....38
Figura 10 – Mapa da dinâmica de uso da terra da área em estudo.....41
Figura 11 – Diagrama de transição de classes para 42
Figura 12 – Diagrama de transição de classes para 42
Figura 13 – Sequência do modelo temporal de 5 anos.....44
Figura 14 – Sequência do modelo temporal de 10 anos para matrizes estimadas diretamente 44
Figura 15 – Sequência do modelo temporal de 10 anos para matrizes extrapoladas.....45
Figura 16 – Sequência do modelo temporal de 15 anos para matrizes estimadas diretamente 46
Figura 17 – Sequência do modelo temporal de 15 anos.....46
Figura 18 – Sequência do modelo temporal de 20 anos.....47
Figura 19 – Sequência do modelo temporal de 20 anos.....47
Figura 20 – Visão geral do procedimento experimental.....49
Figura 21 – Desempenho das classificações por classe em 2004.....55
Figura 22 – Taxas de classificação para Treinamento e Teste em 2004.....55
Figura 23 – Erros de Omissão e Comissão das classificações de Teste em 2004.....56
Figura 24 – Desempenho global das classificações em 2004.....57
Figura 25 – Desempenho das classificações por classe em 1999.....59
Figura 26 – Taxas de classificação para Treinamento e Teste em 1999.....60
Figura 27 – Erros de Omissão e Comissão das classificações de Teste em 1999.....61
Figura 28 – Desempenho global das classificações em 1999.....62
Figura 29 – Desempenho das classificações por classe em 1994.....66
Figura 30 – Taxas de classificação para Treinamento e Teste em 1994.....67
Figura 31 – Erros de Omissão e Comissão das classificações de Teste em 1994.....68
Figura 32 – Desempenho global dos classificadores em 1994.....69
Figura 33 – Desempenho das classificações por classe em 1989.....73

Figura 34 – Taxas de classificação para Treinamento e Teste em 1989.....74
Figura 35 – Erros de Omissão e Comissão das classificações de Teste em 1989.....76
Figura 36 – Desempenho global das classificações em 1989.....77
Figura 37 – Desempenho global dos classificadores.....78
Figura 38 – Ganho médio das classificações multitemporais em relação às monotemporais. .79
Figura 39 – Erros totais das classificações monotemporais e multitemporais.....80
Figura 40 – Espacialização das taxas de acerto da classificação com base em $T_{2009\rightarrow2004}$ 82
Figura 41 – Espacialização das taxas de acerto da classificação com base em $T_{2004\rightarrow1999}$ 83
Figura 42 – Espacialização das taxas de acerto da classificação com base em $T_{2009\rightarrow1999}$ 84
Figura 43 – Espacialização das taxas de acerto da classificação com base em $T^2_{2009\rightarrow2004}$ 84
Figura 44 – Espacialização das taxas de acerto da classificação com base em $T_{1999\rightarrow1994}$ 85
Figura 45 – Espacialização das taxas de acerto da classificação com base em $T_{2004\rightarrow1994}$ 86
Figura 46 – Espacialização das taxas de acerto da classificação com base em $T^2_{2004\rightarrow1999}$ 86
Figura 47 – Espacialização das taxas de acerto da classificação com base em $T_{2009\rightarrow1994}$ 87
Figura 48 – Espacialização das taxas de acerto da classificação com base em $T^3_{2009\rightarrow2004}$ 87
Figura 49 – Espacialização das taxas de acerto da classificação com base em $T_{1994\rightarrow1989}$ 88
Figura 50 – Espacialização das taxas de acerto da classificação com base em $T_{1999\rightarrow1989}$ 89
Figura 51 – Espacialização das taxas de acerto da classificação com base em $T^2_{1999\rightarrow1994}$ 89
Figura 52 – Espacialização das taxas de acerto da classificação com base em $T_{2004\rightarrow1989}$ 90
Figura 53 – Espacialização das taxas de acerto da classificação com base em $T^3_{2004\rightarrow1999}$ 90
Figura 54 – Espacialização das taxas de acerto da classificação com base em $T_{2009\rightarrow1989}$ 91
Figura 55 – Espacialização das taxas de acerto da classificação com base em $T^4_{2009\rightarrow2004}$ 91

LISTA DE TABELAS

Tabela 1 – Matriz de confusão M e cálculo das taxas de classificação.....30
Tabela 2 – Série de imagens utilizadas na pesquisa.....35
Tabela 3 – Classes de cobertura da terra.....39
Tabela 4 – Resultados da classificação Monotemporal de Teste, para 2004.....54
Tabela 5 – Resultados da classificação Multitemporal de Teste com base em $T_{2009\rightarrow2004}$, para 2004.....54
Tabela 6 – Resultados da classificação Monotemporal de Teste, para 1999.....58
Tabela 7 – Resultados da classificação Multitemporal de Teste com base em $T_{2004\rightarrow1999}$, para 1999.....58
Tabela 8 – Resultados da classificação Multitemporal de Teste com base em $T_{2009\rightarrow1999}$, para 1999.....58
Tabela 9 – Resultados da classificação Multitemporal de Teste com base em $T^2_{2009\rightarrow2004}$, para 1999.....59
Tabela 10 – Resultados da classificação Monotemporal de Teste, para 1994.....64
Tabela 11 – Resultados da classificação Multitemporal de Teste com base em $T_{1999\rightarrow1994}$, para 1994.....64
Tabela 12 – Resultados da classificação Multitemporal de Teste com base em $T_{2004\rightarrow1994}$, para 1994.....64
Tabela 13 – Resultados da classificação Multitemporal de Teste com base em $T^2_{2004\rightarrow1999}$, para 1994.....65
Tabela 14 – Resultados da classificação Multitemporal de Teste com base em $T_{2009\rightarrow1994}$, para 1994.....65
Tabela 15 – Resultados da classificação Multitemporal de Teste com base em $T^3_{2009\rightarrow2004}$, para 1994.....65
Tabela 16 – Resultados da classificação Monotemporal de Teste, de 1989.....70
Tabela 17 – Resultados da classificação Multitemporal de Teste com base em $T_{1994\rightarrow1989}$, para 1989.....71
Tabela 18 – Resultados da classificação Multitemporal de Teste com base em $T_{1999\rightarrow1989}$, para 1989.....71
Tabela 19 – Resultados da classificação Multitemporal de Teste com base em $T^2_{1999\rightarrow1994}$, para 1989.....71

Tabela 20 – Resultados da classificação Multitemporal de Teste com base em $T_{2004\rightarrow1989}$, para 1989.....72
Tabela 21 – Resultados da classificação Multitemporal de Teste com base em $T^3_{2004\rightarrow1999}$, para 1989.....72
Tabela 22 – Resultados da classificação Multitemporal de Teste com base em $T_{2009\rightarrow1989}$, para 1989.....72
Tabela 23 – Resultados da classificação Multitemporal de Teste com base em $T^4_{2009\rightarrow2004}$, para 1989.....73
Tabela 24 – Resultados do desempenho global das classificações de Teste, de 2004 a 1989...78
Tabela 25 – Resultados das Erros Totais das classificações de Teste, de 2004 a 1989.....80

SUMÁRIO

INTRODUÇÃO.....14

Objetivos 16

Organização do presente trabalho.....17

1 **TRABALHOS ANTERIORES**.....18

2 **MÉTODO DE CLASSIFICAÇÃO MULTITEMPORAL**.....25

2.1 **Método de Modelagem do Conhecimento Temporal**.....25

2.2 **Método de Classificação Multitemporal**.....27

2.3 **Treinamento do Classificador**.....28

2.4 **Extrapolação de Matrizes de Transição**.....28

2.5 **Metodologia de avaliação dos resultados**.....29

2.5.1 Matriz de confusão e taxas de classificação.....29

2.5.2 Erros de Omissão, Erros de Comissão.....31

2.5.3 Índice Kappa.....31

3 **PROCEDIMENTO EXPERIMENTAL**.....33

3.1 **Área de estudo**.....33

3.2 **Dados de Sensoriamento Remoto**.....34

3.3 **Classificação de referência**.....37

3.4 **Classificação monotemporal**.....39

3.5 **Diagrama de transição de classes**.....40

3.6 **Infraestrutura de Software**.....43

3.7 **Sequência do Modelo Temporal**.....43

3.8 **Modelo do protótipo experimental**.....48

3.9 **Testes e experimentos**.....50

3.9.1 Parâmetros testados não adotados no protótipo experimental.....51

4 **RESULTADOS E DISCUSSÕES**.....53

4.1 **Classificação em 2004**.....53

4.2 **Classificação em 1999**.....57

4.3 **Classificação em 1994**.....63

4.4 **Classificação em 1989**.....69

4.5 **Síntese das Classificações Multitemporais**.....78

4.6 **Espacialização das taxas de acerto das classificações multitemporais**.....81

4.6.1 Espacialização das taxas de acerto para as classificações do ano de 2004.....81

4.6.2 Espacialização das taxas de acerto para as classificações do ano de 1999.....82

4.6.3 Espacialização das taxas de acerto para as classificações do ano de 1994.....85
4.6.4 Espacialização das taxas de acerto para as classificações do ano de 1989.....88
5 **CONCLUSÕES**.....92
REFERÊNCIAS.....95

INTRODUÇÃO

Avanços recentes na tecnologia de sensoriamento remoto, notadamente em relação a sistemas orbitais, têm proporcionado uma oferta crescente de imagens de diferentes características. Tal aumento da disponibilidade de dados, aliada à também crescente oferta de dados gratuitos, tem promovido um considerável aumento no número de pesquisas relacionadas ao tema classificação automática de uso e cobertura da terra e sua dinâmica temporal.

Mapas temáticos, produzidos a partir da interpretação de imagens de uma mesma região e obtidas em diferentes instâncias de tempo, são fundamentais para o estudo da dinâmica do uso e cobertura da terra. Este tipo de abordagem, referida a partir do presente momento pelo termo *análise multitemporal*, permite a identificação das mudanças ocorridas em um determinado período e a análise da dinâmica da cobertura da terra na região em estudo.

Alguns trabalhos podem ser citados como exemplos de estudos multitemporais. Weismiller et al. (1977) procuraram detectar mudanças ambientais em zonas costeiras. Alencar et al. (1996) buscaram compreender a dinâmica do uso da terra e avaliar suas tendências em três municípios do nordeste da Amazônia. Souto e Amaro (2003) trabalharam na identificação de diferenças quanto ao uso e ocupação da terra em um município na região do Rio Grande do Norte. Já Mesquita Jr. e Bittencourt (2003) procuraram elaborar uma análise da dinâmica da vegetação a partir da variação sazonal por modelagem de Índice de Vegetação Digital Normalizada.

A aplicação dos estudos multitemporais se dá principalmente em situações que requerem contínuo monitoramento do uso e cobertura da terra. Um problema importante é que a interpretação visual de imagens de sensoriamento remoto, abordagem comumente empregada na produção de mapas de cobertura ou uso da terra, possui um alto grau de subjetividade. Intérpretes diferentes podem, eventualmente, atribuir classes distintas de uso e cobertura à mesma região geográfica. Nestes casos, há risco da modelagem da dinâmica temporal refletir mudanças inexistentes ou deixar de considerar mudanças ocorridas. Por isto, é mister garantir a coerência do mapeamento temático. Uma das estratégias que permitem caminhar na direção de tal consistência corresponde à utilização de métodos automáticos de interpretação de imagens.

A contribuição científica dos trabalhos de classificação automática supervisionada de imagens (Lillesand et al., 2004; Schowengerdt, 2007) no apoio aos estudos multitemporais deve ser reconhecida. Contudo, na maioria de tais abordagens, simplesmente, imagens adquiridas em diferentes datas são individualmente classificadas. Este procedimento pode ser denominado de classificação monotemporal. Em seguida, os mapas temáticos produzidos são analisados em um contexto multitemporal a fim de se estudar a dinâmica do uso e 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 que está sob análise. Pode-se compreender a superioridade da classificação multitemporal frente à classificação monotemporal pelo fato da primeira utilizar um conjunto mais rico de atributos.

Um ponto comum dos métodos de classificação multitemporal encontrados na literatura 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. (Bruzzone, 2000; Khazenie, Crawford, 1990; Jeon, Langrebe, 1992, 1999; Aach, Kaup, 1995; Solberg et al. 1996; Bruzzone et al. 1999, 2004). No entanto, tais iniciativas não utilizam um modelo explícito de conhecimento temporal no processo de classificação.

As pesquisas que modelam explicitamente a transformação temporal para classificação automática de séries de imagens multitemporais são recentes. Alguns trabalhos anteriores empregaram Cadeias de Markov Fuzzy (CMF) para a representação do conhecimento temporal. (Mota, 2004; Campos et al. 2005; Mota et al., 2007; Feitosa et al., 2009; Costa, 2009; Costa et al., 2009). O modelo proposto em tais trabalhos deu origem a uma abordagem baseada em conhecimento capaz de capturar a correlação existente entre informações temporais e espectrais. Deve ser mencionado, ainda, o fato dos resultados desses trabalhos terem sido consistentemente superiores aos produzidos pela classificação monotemporal.

Assim, a proposta de uso de CMF se caracteriza como uma importante contribuição no que diz respeito à utilização do conhecimento temporal no processo de classificação automática de imagens de sensores remotos. Os significativos resultados das pesquisas anteriores relativas ao uso de CMF em uma abordagem de classificação multitemporal em cascata (Mota, 2004; Campos et al. 2005; Mota et al., 2007; Feitosa et al., 2009; Costa, 2009; Costa et al., 2009; Feitosa et al, 2011) são motivadores do presente trabalho. Mais

especificamente, a proposta é dar sequência à investigação do uso de CMF para a classificação de séries temporais de imagens.

Nos trabalhos anteriores mencionados, as CMF são utilizadas para modelar uma transformação temporal $\mathbf{T}^k$, baseada numa matriz que transporta atributos medidos no passado para o presente. Na maior parte destes trabalhos, a matriz da transformação foi obtida de forma supervisionada a partir de dados de treinamento adquiridos em $\boldsymbol{t}_{p-k}$ e $\boldsymbol{t}_p$, dois momentos separados por k intervalos de tempo. Neste contexto, o tempo encontra-se discretizado em intervalos iguais a $\Delta\boldsymbol{t}$ e $\boldsymbol{t}_i$ representa uma instância de tempo, enquanto o índice $i \in \mathbb{Z}$. A exceção é Feitosa et al. (2011), que analisou diversas configurações do método de classificação multitemporal. Dentre as configurações alternativas, foram comparadas duas estratégias para a obtenção de $\mathbf{T}^2$: a primeira diretamente a partir dos dados adquiridos em $\boldsymbol{t}_{p-2}$ e $\boldsymbol{t}_p$; e a segunda a partir da combinação de duas transformações $\mathbf{T}$ obtidas com base em dados de $\boldsymbol{t}_{p-2}$ e $\boldsymbol{t}_{p-1}$. Tal iniciativa, cuja limitação deriva da série temporal de imagens empregada, que se restringe a três datas, $\boldsymbol{t}_{p-2}$, $\boldsymbol{t}_{p-1}$ e $\boldsymbol{t}_p$, somente, está longe de esgotar o assunto.

Objetivos

O objetivo geral deste trabalho é comparar duas alternativas para a obtenção de $\mathbf{T}^k$: a primeira obtida diretamente a partir dos dados de $\boldsymbol{t}_{p-k}$ e $\boldsymbol{t}_p$; e a segunda utilizando um método de *Extrapolação das Transformações Temporais*, que consiste em combinar k vezes a matriz de transição $\mathbf{T}^1$ obtida para os instantes $\boldsymbol{t}_{p-k}$ e $\boldsymbol{t}_{p-k+1}$.

Como objetivos específicos desta pesquisa, podem ser citados:

- definição de Cadeias de Markov Fuzzy para a série analisada;
- avaliação da extrapolação das matrizes de possibilidades de transição; e
- análise da contribuição do conhecimento multitemporal na classificação de uso da terra em relação à classificação monotemporal.

Cabe ressaltar que neste trabalho foi analisada uma série temporal de imagens mais longa do que as investigadas nas pesquisas correlatas, realizadas anteriormente, e que a área de estudo também apresenta características distintas das regiões previamente exploradas.

Enquanto nos trabalhos anteriores (Mota, 2004; Campos et al. 2005; Mota et al., 2007; Feitosa et al., 2009; Costa et al., 2009; Feitosa et al, 2011) as imagens utilizadas eram de

apenas três instâncias de tempo e intervalo temporal de um ano (1999, 2000 e 2001), no presente trabalho foram utilizadas imagens de 5 instâncias de tempo e intervalo temporal de 5 anos (1989, 1994, 1999, 2004 e 2009). Além disso, área de estudo utilizada nos trabalhos anteriores apresentava cobertura da terra predominantemente agropastoril; na presente pesquisa, utilizou-se uma área de estudo que corresponde a um remanescente florestal.

Organização do presente trabalho

Como forma de facilitar a compreensão da pesquisa, este trabalho foi organizado da seguinte forma. O capítulo 1 apresenta uma breve introdução teórica sobre o tema. No capítulo 2, são descritos o método de classificação multitemporal, o método de extrapolação das transformações temporais e a metodologia de avaliação dos resultados. O capítulo 3 descreve os procedimentos e materiais utilizados para a elaboração do protótipo e na análise experimental. No capítulo 4, os resultados experimentais são analisados e discutidos. Por fim, são apresentadas as conclusões da pesquisa e propostas para trabalhos futuros.

1 TRABALHOS ANTERIORES

Segundo Schowengerdt (2007), o processo de interpretação e classificação de uma imagem de sensoriamento remoto pode ser dividido em três etapas: a) extração de características da imagem; b) treinamento; e c) classificação.

Na etapa "a) extração de características da imagem", determinados dados espectrais e espaciais originais de uma imagem multiespectral são extraídos para possibilitar a utilização de informações mais relevantes para a classificação como, por exemplo, seleção de um subconjunto de bandas, transformação por componentes principais, segmentos ou regiões homogêneas. (SCHOWENGERDT, 2007).

A etapa "b) treinamento" se caracteriza pela especialização de um classificador a fim de que este reconheça automaticamente determinados temas ou classes. Esta etapa envolve a caracterização de classes de objetos do mundo real. No contexto de sensoriamento remoto da superfície terrestre essas classes podem incluir, por exemplo, florestas, recursos hídricos, pastagens e terrenos de outros tipos de cobertura, dependendo da escala geográfica e da natureza do estudo (SCHOWENGERDT, 2007).

Por fim, a etapa "c) classificação" é o processo de decisão para rotulação de cada pixel ou segmento da imagem original, produzindo uma imagem rotulada. Na classificação da imagem digital, esses rótulos são numéricos, de modo que um pixel ou segmento é reconhecido como pertencente a classe "água" pode ser dado o rótulo "1", "floresta" pode ser rotulado como "2" e assim por diante. (SCHOWENGERDT, 2007; MATHER, 2005).

Assim, necessariamente, o processo de classificação de imagens exige que o usuário determine a priori o número e a natureza das classes de interesse. E, além disto, atribua rótulos aos pixels ou segmentos com base em suas propriedades através de um processo de tomada de decisão, normalmente referido pelo termo regra de classificação ou de decisão. (MATHER, 2005).

O procedimento de classificação pode ser supervisionado por um especialista ou não supervisionado. Em uma classificação supervisionada, na etapa do treinamento, o especialista irá associar rótulos às amostras das classes de interesse. Já a classificação não supervisionada está relacionada a um processo de *clustering*, que não exige a definição prévia de um conjunto de classes. *Clustering* é um tipo de procedimento exploratório, cujo objetivo é determinar o número (mas não a identidade inicialmente) de categorias presentes na área coberta pela

imagem, e para alocar os pixels ou segmentos a essas categorias. A identificação dos grupos ou categorias em função da natureza dos tipos de cobertura da terra é uma fase separada que acompanha o processo de *clustering* (MATHER, 2005).

Medidas baseadas nos valores de tons de cinza associados a um pixel ou a um conjunto de pixels que compõem um segmento, bem como parâmetros morfológicos ou texturais dos segmentos, são exemplos de características comuns na literatura. As classes a serem discriminadas no processo de classificação são caracterizadas por padrões específicos derivados do conjunto de características consideradas. O processo de classificação é, portanto, o reconhecimento de padrões. (MATHER, 2005).

As etapas cruciais de métodos de reconhecimento de padrões envolvem a seleção de um conjunto de características que melhor descrevem as classes de interesse e a escolha de um método adequado para a comparação entre as propriedades dos objetos (pixel ou segmento) a serem classificados e os padrões alvo. Em aplicações de sensoriamento remoto, é usual incluir uma terceira fase - análise da exatidão do processo de reconhecimento. (MATHER, 2005).

Segundo Mota (2004), para a interpretação de uma imagem, três principais aspectos devem ser considerados: os atributos espectrais, os atributos espaciais e os atributos temporais. Ao contrário do olho humano, que possui limitada capacidade de reconhecer diferenças entre níveis tonais similares e de analisar simultaneamente um grande número de bandas, um computador pode realizar uma análise espectral assistida mais rápida e sem restrições quanto ao número de bandas. No entanto, quando a resposta espectral das classes é muito semelhante, mesmo com toda a capacidade computacional atualmente disponível, a classificação baseada apenas em atributos espectrais pode não proporcionar resultados satisfatórios. Por isso, ainda hoje, para garantir a qualidade do mapeamento temático, mesmo nos casos onde são empregados métodos automáticos de reconhecimento do padrões, se faz necessária a intervenção humana.

Os métodos automáticos, por sua vez, encontram dificuldades para discriminar, a partir das características espaciais, objetos com resposta espectral semelhante. Nesses casos, a intervenção humana pode auxiliar o processo de classificação, dada a capacidade de um fotointérprete discriminar visualmente diferentes padrões espaciais. Algumas classes como “mata ciliar” e “mangue” podem ser citadas como exemplos de alvos que apresentam resposta espectral muito semelhante, mas com padrões espaciais significativamente diferentes. Para a classe “mata ciliar”, um atributo espacial pode ser sua localização em relevos com

características acidentadas, de maior declividade e próximo a redes hidrográficas. Enquanto para a classe “mangue”, um atributo espacial pode ser a utilização de áreas mais extensas e de relevo plano, sem declividade, geralmente próximo ao mar. Além disso, uma mesma classe pode ocorrer em mais de um contexto espacial. Assim, a definição de uma base de conhecimento capaz de compreender todas as relações espaciais existentes na área sob análise pode ser uma tarefa árdua.

Além dos atributo espectrais e espaciais, atributos temporais e de conhecimento temporal, estão relacionados à capacidade dos fotointérpretes utilizarem um conjunto de dados anteriores, relativos à mesma região, durante a interpretação visual. Neste processo, o intérprete se vale de conhecimento a respeito da dinâmica dos objetos e das classes da área de estudo. Segundo Growe (1999), conhecimento sobre a dinâmica dos objetos numa dada região pode ser incorporado à processos de classificação automática a fim de aumentar a confiabilidade do resultado.

Diversos métodos de interpretação e classificação automática de imagens de sensoriamento remoto podem ser observados na literatura. (Lillesand et al., 2004; Schowengerdt, 2007; Clement, 1993; Mather, 2005; Mather; Tso, 2009). No âmbito da classificação automática de imagens, a proposta apresentada por Feitosa et al. (2009) se caracteriza como uma importante contribuição para o uso do conhecimento temporal no processo de interpretação de imagens orbitais. Neste trabalho, os autores dão continuidade à proposta original de Mota et al. (2007), em que é empregado um método de classificação fuzzy em cascata, que se vale de toda a informação contida na sequência de imagens multitemporais. Feitosa et al. (2009), por sua vez, formalizam, no método em cascata, o uso de Cadeias de Markov Fuzzy, que dão suporte teórico à chamada transformação temporal – atualização de informações pretéritas para o apoio à classificação em instantes de tempo posteriores.

O presente trabalho adota como referência e dá sequência às pesquisas que modelam explicitamente, através de Cadeias de Markov *Fuzzy* (CMF), a transformação temporal com objetivo de classificar séries de imagens multitemporais. (Mota, 2004; Campos et al., 2005; Mota et al., 2007; Costa et al., 2007; Feitosa et al., 2009; Costa, 2009; Costa et al., 2009). Estes métodos de classificação "em cascata" utilizam toda a informação contida na sequência de imagens, tentando tirar proveito da correlação temporal entre as imagens. (FEITOSA et al., 2009).

No trabalho que deu início à série de pesquisas relacionadas ao tema, Mota (2004)

propôs um método de classificação *fuzzy* em cascata empregando um tratamento possibilístico para conhecimento temporal. O autor investigou a representação de conhecimento na interpretação de imagens multitemporais de média resolução, onde o principal objetivo foi propor um modelo para a interpretação baseada em conhecimento (combinando conhecimento espectral, contextual e temporal), visando reproduzir o raciocínio empregado pelo fotointéprete ao realizar uma interpretação visual. O trabalho explicita a contribuição de cada modalidade de conhecimento no processo de interpretação.

O conhecimento temporal foi representado a partir de um diagrama de transição de estados, onde foram atribuídos valores para cada possibilidade de transição entre classes, visando expressar a relação entre a classe de um objeto num dado momento e a classe do mesmo objeto num instante posterior.

Para realização dos experimentos foram utilizadas imagens Landsat (WRS II 224-073), composição RGB / 5, 4 e 3 do sensor ETM+, dos anos de 1999, 2000 e 2001, de duas regiões inseridas na Alta Bacia do Rio Taquari, ao leste do pantanal mato-grossense.

Como principais conclusões, Mota (2004) verificou que os resultados obtidos com o uso de conhecimento contextual foram sempre superiores aos resultados produzidos pela classificação baseada unicamente em características espectrais, indicando que o uso de abordagens baseadas em conhecimento temporal pode contribuir significativamente para a automação do processo de interpretação. O trabalho concluiu também que, de forma individual, dentre as diversas modalidades de conhecimento empregadas, o conhecimento temporal demonstrou fornecer o maior incremento na taxa de reconhecimento global, em relação à classificação meramente espectral.

Campos et al. (2005) propõem um procedimento automático de modelagem do conhecimento multitemporal. Diferentemente do ocorrido no trabalho de Mota (2004), onde os valores das possibilidades de transição, modelados por um diagrama de transição de estados, representando a dinâmica na região, foram definidos por um especialista, Campos et al. (2005) propõem a estimação supervisionada destes valores utilizando algoritmos genéticos (AG). Para validação da metodologia proposta, foi utilizada a mesma base de dados utilizada nos experimentos de Mota (2004). Como resultado, os autores concluíram que o uso de algoritmos genéticos apresentou desempenho superior na classificação, em comparação à estimativa manual dos parâmetros do modelo multitemporal.

Mota et al. (2007) propõem uma nova estrutura de interpretação multitemporal para atualização regular de mapas de uso e cobertura da terra. O método proposto utiliza

possibilidades de transição de classes para expressar a correlação temporal entre as classes de interesse. As possibilidades de transição de classe são estimadas por meio de um algoritmo genético cuja função objetivo é a taxa de reconhecimento média por classe. A partir de uma classificação de referência de uma determinada data da região de interesse e dos valores das possibilidades de transição de classes, uma classificação *fuzzy* é obtida. Em seguida, esta classificação é fundida com a saída de uma classificação *fuzzy* sobre uma imagem de data posterior. O método adotado pelos autores originou um procedimento de classificação multitemporal *fuzzy* que combina os diversas modalidades de conhecimento.

Podem ser citadas como principais contribuições deste trabalho: um método de modelagem temporal de conhecimento contendo um novo procedimento para estimar as possibilidades de transição de classe, um método para integrar informações de instantes de tempo distintos, que é capaz de captar a correlação temporal, e uma avaliação da contribuição potencial do conhecimento temporal, em comparação com outras formas de conhecimento.

Os experimentos, realizados com a mesma base de dados Mota (2004), mostraram que o uso do conhecimento prévio melhorou consideravelmente o desempenho da classificação em comparação com uma classificação baseada apenas em características espectrais.

Vale ressaltar que, apesar de não mencionar diretamente o uso de Cadeias de Markov Fuzzy em seus trabalhos, Mota (2004), Campos et al. (2005) e Mota et al. (2007), fizeram uso de seus conceitos com a elaboração de diagrama de transição de estados como forma de representação do conhecimento multitemporal.

Costa et al. (2007) dá sequência às pesquisas anteriores e utiliza, pela primeira vez, o conceito de Cadeias de Markov Fuzzy no procedimento de classificação multitemporal. Como inovação, a pesquisa visa contornar a limitação da necessidade da "verdade de campo" da mesma área geográfica numa data anterior e apresenta uma generalização do modelo apresentado por Campos et al. (2005) e Mota et al. (2007).

Os resultados obtidos por Costa et al. (2007) demonstraram a superioridade do método multitemporal frente à abordagem monotemporal. Nos experimentos, observou-se, ainda, que o ganho de desempenho depende primordialmente de dois fatores: a exatidão dos classificadores monotemporais que compõem o esquema multitemporal e o lapso de tempo que separa as imagens multitemporais. Assim, quanto mais recente é a informação passada, maior sua contribuição para a classificação.

Feitosa et al. (2009) apresentam como limitação da abordagem proposta em Mota et al. (2007) a necessidade de se utilizar uma classificação de referência de uma data anterior,

essencialmente porque essa informação muitas vezes não é disponível. Os autores propõem um método que elimina essa limitação. Assim, a informação sobre o estado dos objetos na data anterior necessária passa a ser, simplesmente, uma imagem da mesma área geográfica. São requeridas, portanto, apenas algumas amostras de treinamento cuja classificação na data posterior seja conhecida. Outra inovação da proposta é uma estrutura conceitual baseada em Cadeias de Markov Fuzzy.

Como resultado, os autores verificaram que a correlação entre dois conjuntos de dados temporais só traz benefícios se essa correlação for significativa. Além disso, observam que ao tomar atributos de duas datas, em vez de uma, o método usa mais informações sobre o objeto que está sendo classificado. Assim, cada objeto é descrito por duas vezes mais atributos que em um método monotemporal. Contudo, uma vez que todas as possíveis transições de classe devem ser representadas no conjunto de treinamento, o processo de coleta de amostras acaba por ser trabalhoso.

Os resultados da análise experimental mostraram uma melhora notável no desempenho e uma significativa correlação entre os conjuntos de dados de tempos distintos. Nesse sentido, o uso dos classificadores monotemporais que participam da classificação multitemporal é uma questão central, podendo melhorar ou mascarar a correlação temporal. Ao ser comparado com outras duas técnicas de classificação em cascata, o método, para a base de dados utilizada, mostrou-se superior.

Costa (2009) investiga a representação explícita de conhecimento temporal e sua integração com outros tipos de conhecimento e, também, o processamento e aquisição automática de conhecimento temporal. Este trabalho desenvolveu um método analítico de estimação das possibilidades de transição e, ainda, concebeu e implementou uma estrutura baseada no conhecimento para a interpretação multitemporal de imagens de sensoriamento remoto no software GeoAIDA.

Feitosa et al. (2011) comparam diversas configurações do método de classificação multitemporal em cascata com base em CMF, considerando também diferentes implementações dos operadores *fuzzy t-norm* e *s-norm*, além da função de agregação *fuzzy*. Os resultados desta investigação permitiram o aprofundamento do entendimento das qualidades e limitações da abordagem.

Por fim, em Alves et al. (2011) os autores publicaram o método e os resultados preliminares da análise experimental presente nesta dissertação. Seu objetivo é dar início à análise de um aspecto da classificação multitemporal em cascata pouco explorado em

trabalhos anteriores: a utilização da combinação de Cadeias de Markov *Fuzzy* de intervalos curtos como alternativa para a obtenção de CMF para intervalos mais longos. Deve ser mencionado que Feitosa et al. (2011) haviam analisado esta alternativa, contudo, de forma bastante limitada. Para tanto, os autores de Alves et al. (2011) utilizaram uma nova base de dados de um intervalo total de 20 anos, com o uso de 5 imagens obtidas com um intervalo de 5 anos entre cada par. Os resultados da classificação multitemporal, tanto para intervalo de tempos curtos, quanto para intervalos de tempo longos, realizada a partir da combinação de CMF, foram superiores à classificação monotemporal, demonstrando o potencial do método de estimação apresentado na presente dissertação.

2 MÉTODO DE CLASSIFICAÇÃO MULTITEMPORAL

Basicamente, o método de classificação multitemporal abordado no presente trabalho se vale de informações adquiridas no passado para melhorar a exatidão do mapa temático produzido pelo processo de classificação. Para tanto, o conhecimento temporal transporta para o presente informações obtidas no passado e as insere no processo de decisão da classificação. Assim, neste método de classificação, a modelagem do conhecimento temporal realiza um papel crucial. A seção a seguir aborda este tema.

2.1 Método de 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. (CHING, NG, 2006).

A grande diferença entre uma cadeia de Markov convencional e uma CMF é que a cadeia de Markov convencional dá suporte a um tratamento probabilístico, enquanto a CMF dá suporte a um tratamento possibilístico. O leitor interessado numa descrição mais geral e detalhada do conceito de CMF pode recorrer a Avrachenkov e Sanchez (2002).

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

Os estados da CMF correspondem, na aplicação, a um conjunto de classes de uso/cobertura do solo $\mathbf{\Omega} = \{\omega_1, \omega_2, \ldots, \omega_c\}$, onde c corresponde ao número de classes. O valor de c não varia ao longo do tempo. A matriz de possibilidades de transição $\mathbf{T}^1 = \{\tau_{ij}\}$ corresponde a uma relação nebulosa binária definida sobre o produto cartesiano $\mathbf{\Omega}\times\mathbf{\Omega}$. O símbolo τ_{ij} denota a possibilidade de um objeto pertencer à classe $\omega_i \in \mathbf{\Omega}$ no instante t e à classe $\omega_j \in \mathbf{\Omega}$ no instante t+1, uma unidade de tempo posterior, sendo $0 \leq \tau_{ij} \leq 1$ para $i,j = 1, \ldots, c$. 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.

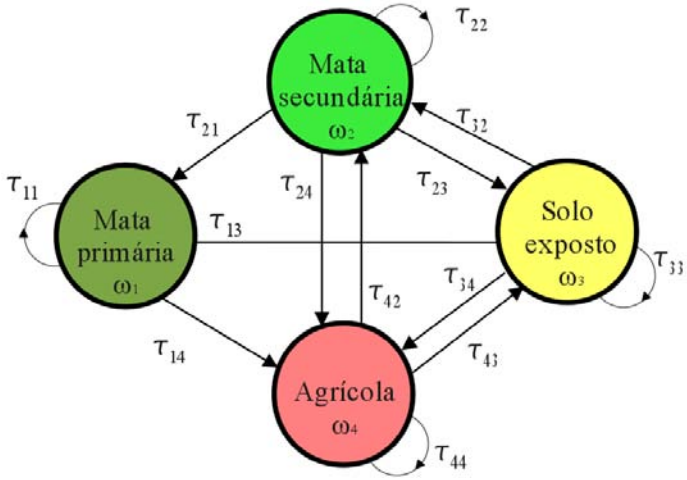

Figura 1 – Digrama de Transição de Estados

Tomando como base o vetor nebuloso ${}^{t}\boldsymbol{\alpha}$, que expressa as pertinências de um determinado objeto às classes $\boldsymbol{\Omega}$ no tempo t, e a matriz de transição $\mathbf{T}^1$, o modelo de Cadeia de Markov Fuzzy pode estimar para o objeto, através de sua lei de transição (Equação 1) os valores de pertinência, ${}^{t+1}\boldsymbol{\beta} = [\,{}^{t+1}\beta_1, \ldots, {}^{t+1}\beta_c\,]$, para uma unidade de tempo posterior.

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

Os símbolos $\top$ e $\perp$ na Equação 1 representam respectivamente uma *t-norm* e uma *s-norm*. Neste trabalho, 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.

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

onde:

- ${}^{t+k}\boldsymbol{\beta}$ – vetor de pertinências para uma unidade de tempo posterior;
- ${}^{t}\boldsymbol{\alpha}$ – vetor que expressa as pertinências de um determinado objeto pertencer às

classes Ω no tempo t;

- $\mathbf{T}^1$ – matriz de transição.

2.2 Método de Classificação Multitemporal

O procedimento de classificação multitemporal é apresentado na Figura 2. De maneira simplificada, o método consiste na fusão de dois conjuntos de dados: a) o vetor de valores de pertinência *fuzzy* ${}^{t+k}\boldsymbol{\alpha}$, fornecido 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 expressa pela matriz de possibilidades de transição $\mathbf{T}^k$ ao vetor crisp ${}^{t}\mathbf{w}$, que representa a classificação num instante passado, simbolizado por t (na presente pesquisa, a classificação num instante passado, simbolizado por t, é uma classificação de referência). O vetor ${}^{t}\mathbf{w}$ é um vetor unitário n-dimensional com a forma [0 … 1 … 0], tendo "1" na posição i e "0" em todas as outras, indicando que o objeto pertence à classe ω_i no instante t.

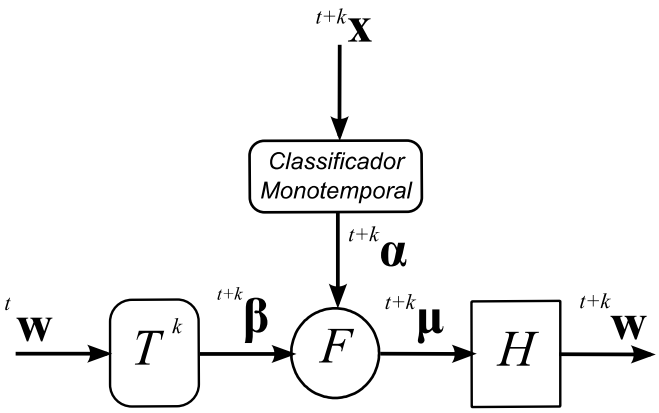

Figura 2 – Método de classificação multitemporal

Conforme pode ser observado na Figura 2, o vetor de pertinências ${}^{t+k}\boldsymbol{\mu}$ é o resultado da fusão de ${}^{t+k}\boldsymbol{\alpha}$ 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.

2.3 Treinamento do Classificador

A geração do vetor de pertinências temporais ${}^{t+k}\boldsymbol{\beta}$ requer a estimação das possibilidades de transição que compõem a matriz de transição $\mathbf{T}^k$. 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) (NIX, VOSE, 1992).

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.

Neste trabalho, cada indivíduo do AG representa uma matriz de transição. A função de avaliação mede a exatidão da classificação multitemporal em $t+k$, obtida usando as possibilidades de transição codificadas no indivíduo. Após um dado número de gerações, o melhor indivíduo da população é selecionado. Os AGs são inspirados na ideia de que, a cada geração, a população tende a evoluir, ficando cada vez mais apta a sobreviver à seleção natural.

2.4 Extrapolação de Matrizes de Transição

O método de Extrapolação de Matrizes de Transição consiste em combinar k vezes a matriz de transição $\mathbf{T}^1$, calculada para os instantes t e $t+1$, com o objetivo de se obter uma matriz combinada $\mathbf{T}^k$, que se refere aos instantes t e $t+k$. A operação de combinação, simbolizada por $\circ$, corresponde ao produto de matrizes substituindo-se o produto e a soma dos escalares por $\top$ 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.

$$\mathbf{T}^2 = \mathbf{T}^1 \circ \mathbf{T}^1$$
$$\mathbf{T}^k = \mathbf{T}^{(k-1)} \circ \mathbf{T}^1 \qquad (3)$$

2.5 Metodologia de avaliação dos resultados

A metodologia de avaliação baseia-se na comparação dos resultados da classificação multitemporal com uma classificação de referência (gabarito), gerada por um especialista humano.

Para isso, para cada classificação é gerada uma matriz de confusão que contém informações sobre a classificação em análise e a classificação de referência, o que permite identificar as discordâncias entre a classificação de referência e a produzida pelo método sob análise. A partir desta matriz de confusão, pode ser calculado o índice Kappa, as taxas de classificação por classe, os erros de omissão, erros de comissão e os erros totais da classificação em análise.

As subseções seguintes detalham os métodos de avaliação.

2.5.1 Matriz de confusão e taxas de classificação

A matriz de confusão é a forma mais comum utilizada para representar a exatidão da classificação. Trata-se de uma matriz de dimensão $n \times n$ (onde n é o número de classes) que representa o grau de concordância entre dois julgamentos feitos de forma independente sobre o mesmo conjunto de dados. No presente caso, o julgamento consiste em associar os objetos a uma dentre n classes (COHEN, 1960).

Ao longo da presente dissertação, as colunas se referem aos dados de referência enquanto as linhas ao julgamento atribuído pelo classificador.

No caso de uma classificação de segmentos, os elementos/valores da matriz de confusão se referem à quantidade de segmentos da classificação. No entanto, se a classificação for realizada com base na classificação de pixels, em sua matriz de confusão os valores serão referidos pelo número de pixels da imagem classificada. É importante destacar que, no presente trabalho, os experimentos realizam a classificação de segmentos. Na

literatura, este tipo de abordagem é referida pelo termo classificação orientada a objetos.

A Tabela 1 apresenta um exemplo de matriz de confusão **M**, de dimensões 4x4, onde as classes são representadas pelas letras *a*, *b*, *c*, e *d*, e o total de objetos a serem classificados é representado por *N*. As colunas correspondem à classificação de referência enquanto as linhas à classificação sob análise.

Tabela 1 – Matriz de confusão **M** e cálculo das taxas de classificação

		Classificação de Referência				***Somatório das Linhas***
	Classes	***a***	***b***	***c***	***d***	
Classificação sob Análise	***a***	$\boldsymbol{m_{aa}}$	m_{ab}	m_{ac}	m_{ad}	$\sum_{i=a} m_{ij}$
	b	m_{ba}	$\boldsymbol{m_{bb}}$	m_{bc}	m_{bd}	$\sum_{i=b} m_{ij}$
	c	m_{ca}	m_{cb}	$\boldsymbol{m_{cc}}$	m_{cd}	$\sum_{i=c} m_{ij}$
	d	m_{da}	m_{db}	m_{dc}	$\boldsymbol{m_{dd}}$	$\sum_{i=d} m_{ij}$
Somatório das Colunas		$\sum_{j=a} m_{ij}$	$\sum_{j=b} m_{ij}$	$\sum_{j=c} m_{ij}$	$\sum_{j=d} m_{ij}$	$N = \sum_{i=a}^{i=d} \sum_{j=a}^{j=d} m_{ij}$
Taxas (%) de Classificação Tx		$Tx_a = \left(\frac{m_{aa}}{\sum_{j=a} m_{ij}} \right) \times 100$	$Tx_b = \left(\frac{m_{bb}}{\sum_{j=b} m_{ij}} \right) \times 100$	$Tx_c = \left(\frac{m_{cc}}{\sum_{j=c} m_{ij}} \right) \times 100$	$Tx_d = \left(\frac{m_{dd}}{\sum_{j=d} m_{ij}} \right) \times 100$	$Tx = \left(\frac{\sum_{i=a}^{d} m_{ii}}{\sum_{j=a}^{d} \sum_{j=a}^{d} m_{ij}} \right) \times 100$

Os elementos na diagonal principal da matriz de confusão representam o número de segmentos em que há concordância entre a referência e o classificador avaliado. O somatório de uma linha da matriz **M** mostra como resultado a quantidade segmentos que foram considerados pelo classificador com pertencentes à respectiva classe. (MATHER; TSO, 2009).

Os valores fora da diagonal principal da matriz, representam os segmentos que foram classificados erroneamente. Por exemplo, na coluna da classe ***b***, m_{bb} são os segmentos classificados corretamente, enquanto os demais (m_{ab}, m_{cb} e m_{db}) são os segmentos que foram classificados erroneamente.

Assim, uma vez que é possível identificar o número de segmentos classificados corretamente e o número de segmentos classificados erroneamente, pode-se calcular a taxa de classificação por classe, que indica a exatidão do classificador para determinada classe.

Para se calcular a Taxa de Classificação por Classe Tx_a, divide-se o número de segmentos classificados corretamente para determinada classe (m_{aa}) pelo somatório de segmentos daquela coluna ($\sum_{j=a} m_{ij}$) e, em seguida, o resultado é multiplicado por 100 a fim de

se obter o percentual de acerto.

É possível, também, calcular a exatidão global *Tx* da matriz de confusão, com o objetivo de medir o total de acertos da classificação.

2.5.2 Erros de Omissão, Erros de Comissão

Ainda com base na matriz de confusão é possível calcular, classe a classe, indicadores de erro. No trabalho, as duas medidas utilizadas são Erro de Omissão (EO) e Erro de Comissão (EC).

Erros de Omissão são cometidos quando padrões de uma determinada classe são atribuídos a alguma outra classe. Por outro lado, os Erros de Comissão ocorrem quando objetos que são realmente membros de outras classes são rotulados como membros da classe para a qual o EC está sendo calculado (MATHER, 2005).

O Erro de Omissão pode ser calculado pela seguinte fórmula:

$$EO_j = \left(1 - \frac{m_{ij}}{\sum_{i=1}^{n} m_{ij}}\right) \times 100\,\% \tag{4}$$

onde m_{jj} é a entrada (i, *j*) da matriz de confusão, $\sum_{j=1}^{n} m_{ij}$ representa o somatório da linha *j*.

Já o Erro de Omissão pode ser calculado por:

$$EC_i = \left(1 - \frac{m_{ij}}{\sum_{j=1}^{n} m_{ij}}\right) \times 100\,\% \tag{5}$$

onde m_{ij} é a entrada (*i, j*) da matriz de confusão e $\sum_{j=1}^{n} m_{ij}$ corresponde ao somatório da coluna *i*.

2.5.3 Índice Kappa

Como alternativa aos métodos de medir a exatidão da classificação através das taxas de classificação por classe e exatidão global, o índice multivariado chamado de coeficiente

Kappa tem sido muito utilizado.

O índice Kappa é um coeficiente para medir o grau de concordância em escalas nominais (Cohen, 1960), ou seja, é um coeficiente de concordância que informa o acerto da variação intra e interobservador, sendo utilizado quando dois observadores classificam separadamente uma amostra de objetos empregando a mesma escala de classes. Normalmente um dos observadores é a referência real ou verdade (INPE, 2009c).

O coeficiente Kappa é calculado pelas seguintes equações, conforme expressam Mather e Tso (2009):

$$\hat{\kappa} = \frac{\theta_1 - \theta_2}{1 - \theta_2} \tag{6}$$

$$\theta_1 = \frac{1}{N} \sum_{i=1}^{n} m_{ii} \tag{7}$$

$$\theta_2 = \frac{1}{N^2} \sum_{k=1}^{n} \left(\sum_{i=1}^{n} m_{ik} \times \sum_{j=1}^{n} m_{kj} \right) \tag{8}$$

Nestas equações, $\hat{\kappa}$ é o coeficiente Kappa, n o número de colunas (e linhas) em uma matriz de confusão, m_{ij} é o elemento (i, j) da matriz de confusão e N é o número total de observações (TSO, MATHER, 2009).

O valor do coeficiente Kappa pode atingir o valor limite superior de +1.00, que ocorre somente existe concordância perfeita entre os dois observadores. Já o limite inferior depende das distribuições marginais, podendo chegar a ser um valor negativo (COHEN, 1960).

3 PROCEDIMENTO EXPERIMENTAL

Esta seção apresenta o procedimento experimental realizado com o intuito de avaliar o desempenho da classificação multitemporal produzida com base em $\mathbf{T}^k$, obtido a partir da combinação de $\mathbf{T}^1$ (conforme descrito na Seção 2.4).

As subseções a seguir detalham os procedimentos experimentais, e estão divididas em: área de estudo, dados de sensoriamento remoto, classificação de referência, classificação monotemporal, diagrama de transição de classes, infraestrutura de software, sequência do modelo temporal e, por fim, testes e experimentos preliminares.

3.1 Área de estudo

A Figura 3 apresenta, em sua porção esquerda, a localização da área de estudo e na direita suas fronteiras (borda preta). A área de estudo corresponde a um remanescente florestal situado no oeste do município de Londrina, estado do Paraná, que incorpora toda a área do Parque Estadual Mata dos Godoy (PEMG) e, também, a área referente a outras duas fazendas de propriedade particular situadas a leste dos limites do parque. Na Figura 3, a borda amarela define os limites do PEMG e a linha laranja as regiões de propriedade particular compreendidas na área de estudo.

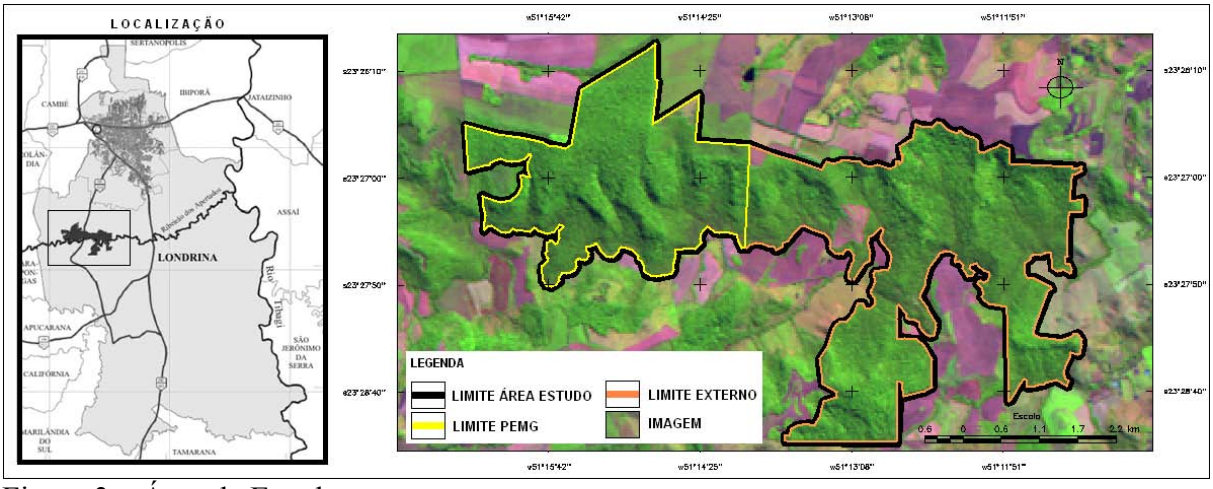

Figura 3 – Área de Estudo

Até junho de 1989, o Parque Estadual Mata dos Godoy pertencia à Fazenda Santa Helena, de propriedade da família Godoy, tendo sido adquirida e incorporada ao patrimônio do Estado do Paraná através do Decreto Estadual no 5.150, de 05/06/1989 (ALVES, PEREIRA NETO, 2010).

A floresta existente é um dos últimos remanescentes de Floresta Subtropical (Floresta Estacional Semidecidual) que cobria grande parte do Estado. Atualmente, este remanescente está circundado por áreas ocupadas pela agricultura e pecuária, sujeito as pressões antrópicas. Este cenário é resultante de um processo que se iniciou na metade do século XIX, quando a agricultura passou a ter um peso maior na economia do Estado do Paraná (IAP, 2002).

3.2 Dados de Sensoriamento Remoto

As imagens selecionadas para a pesquisa foram as do satélite Landsat 5, sensor TM. A razão para o uso de imagens Landsat 5 se deve ao fato deste satélite ter permanecido ativo por mais de 20 anos, possibilitando que todas as imagens utilizadas fossem de um único sensor. As imagens foram selecionadas com intervalo temporal de 5 anos, contados a partir do ano de 1989 (ano de criação do PEMG) até o ano de 2009, seguindo os critérios de seleção de cenas da mesma época do ano e com 0% de cobertura de nuvem para a área em estudo.

As bandas utilizadas para classificação foram a 3 (vermelho), 4 (infravermelho próximo) e 5 (infravermelho médio). O *composite* utilizado compreende o uso das bandas 5, 4 e 3 nos canais R, G e B respectivamente. Este arranjo é comumente utilizado no monitoramento da cobertura vegetal (PRODES, 2006).

A Tabela 2 apresenta a série de imagens, obtidas gratuitamente pelo catálogo de imagens do INPE (INPE, 2009b).

As imagens foram devidamente registradas com o uso do software Spring 5.1.4, a partir de uma imagem de referência Landsat 7 ETM+, ortorretificada, banda 7 – pancromática, de 15m de resolução espacial nominal, adquirida gratuitamente pelo catálogo de imagens do projeto *Global Land Cover Facility* (GLCF, 2009). Após o registro, as imagens foram recortadas para o limite da área de estudo.

Tabela 2 – Série de imagens utilizadas na pesquisa.

Satélite / Sensor	Data das Imagens	Bandas	Resolução Espacial
Landsat 5 TM	03/08/1989	3, 4 e 5	30m
Landsat 5 TM	16/07/1994	3, 4 e 5	30m
Landsat 5 TM	14/07/1999	3, 4 e 5	30m
Landsat 5 TM	27/07/2004	3, 4 e 5	30m
Landsat 5 TM	22/05/2006	3, 4 e 5	30m

Com o objetivo de não alterar suas características espectrais, além do registro e recorte não foi realizado nenhuma outra técnica de pré-processamento de imagens.

As Figuras 4, 5, 6, 7 e 8, correspondem respectivamente as imagens dos anos 1989, 1999, 2004, e 2009. É importante lembrar que as imagens apresentadas nesta seção foram realçadas com o intuito de melhorar sua visualização. As imagens utilizadas nos experimentos não apresentavam nenhum tipo de realce.

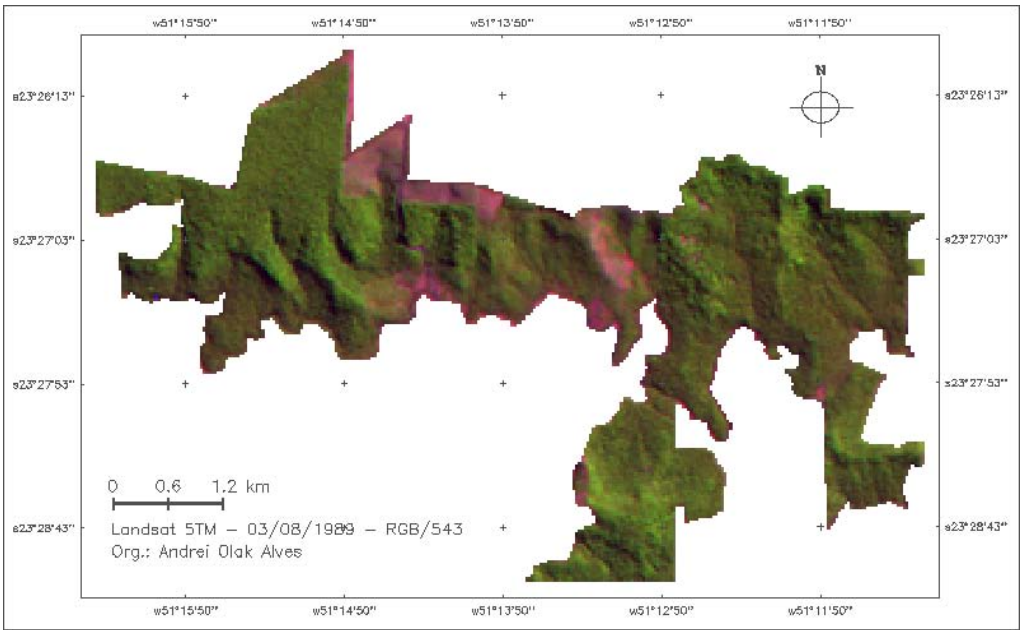

Figura 4 – Imagem de 1989

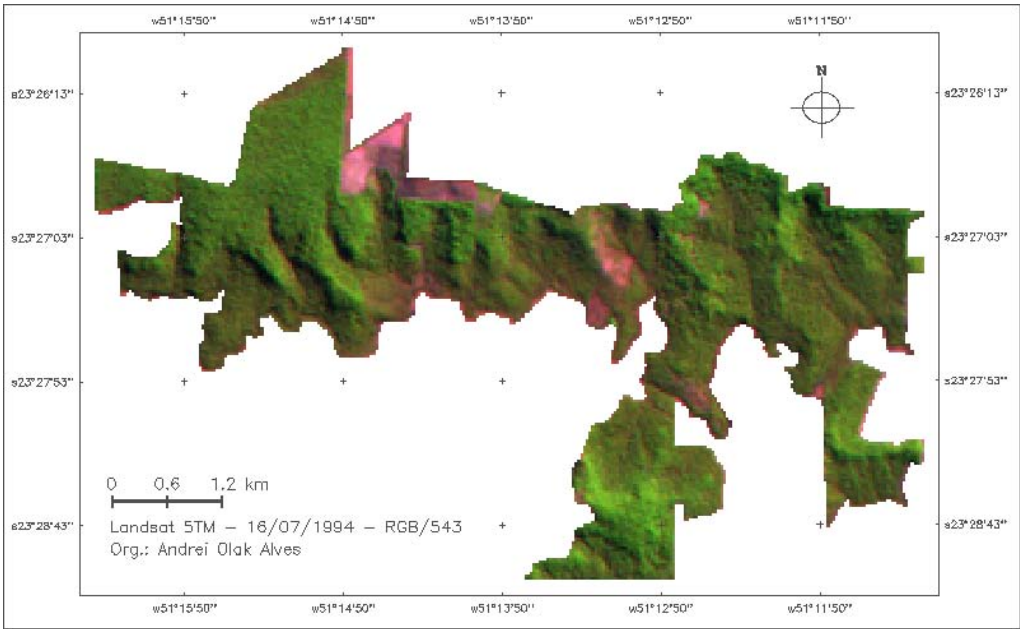

Figura 5 – Imagem de 1994

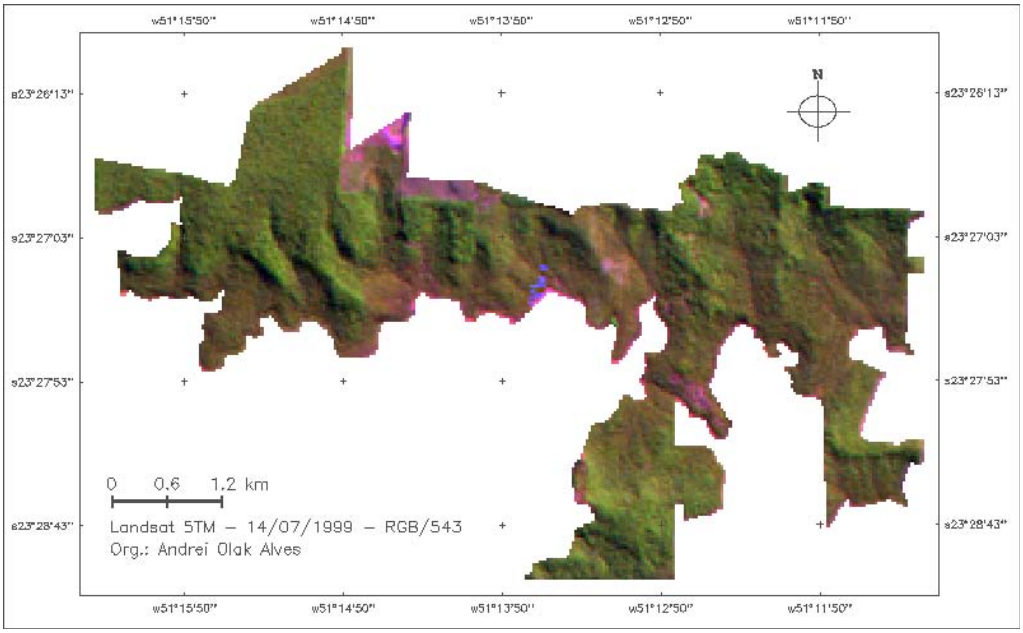

Figura 6 – Imagem de 1999

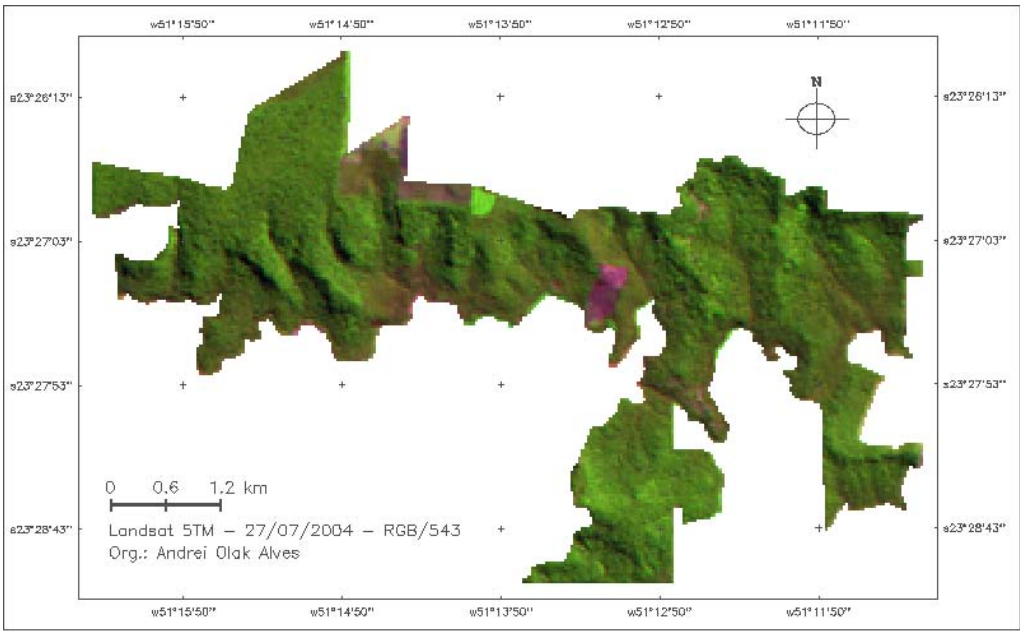

Figura 7 – Imagem de 2004

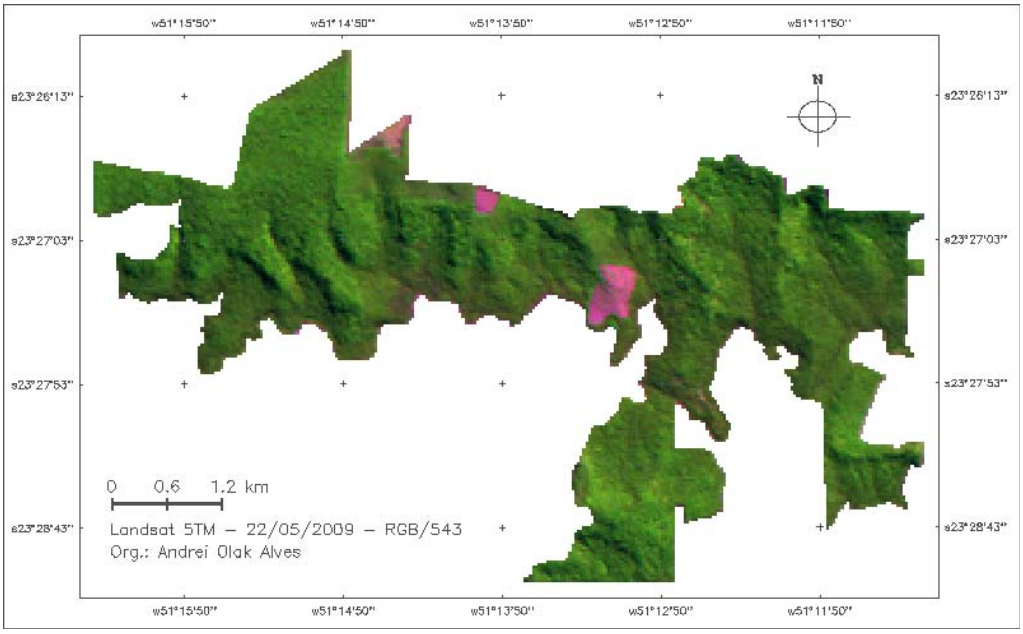

Figura 8 – Imagem de 2009

3.3 Classificação de referência

A classificação de referência foi gerada por um especialista humano que, além de analisar as imagens de sensoriamento remoto em um contexto multitemporal, fez uso de informações adicionais como do Plano de Manejo do Parque Estadual Mata dos Godoy,

imagens de maior resolução espectral (SPOT, do ano de 2000) e trabalho de campo.

Ainda, vale ressaltar que o especialista já realizou pesquisas anteriores relacionadas à dinâmica da área de estudo (ALVES, 2006; ALVES, PEREIRA NETO, 2010).

Para gerar as classificações de referência, as imagens de sensoriamento foram segmentadas no software SPRING 5.1.4, utilizando o algoritmo de segmentação por crescimento de regiões. O procedimento foi semelhante ao utilizado em Mota et al. (2007), Feitosa et al. (2009) e Costa et al. (2009), conforme descrito a seguir. 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.

Posteriormente, a classificação de referência dos segmentos foi realizada para cada um dos cinco instantes de tempo (Figura 9).

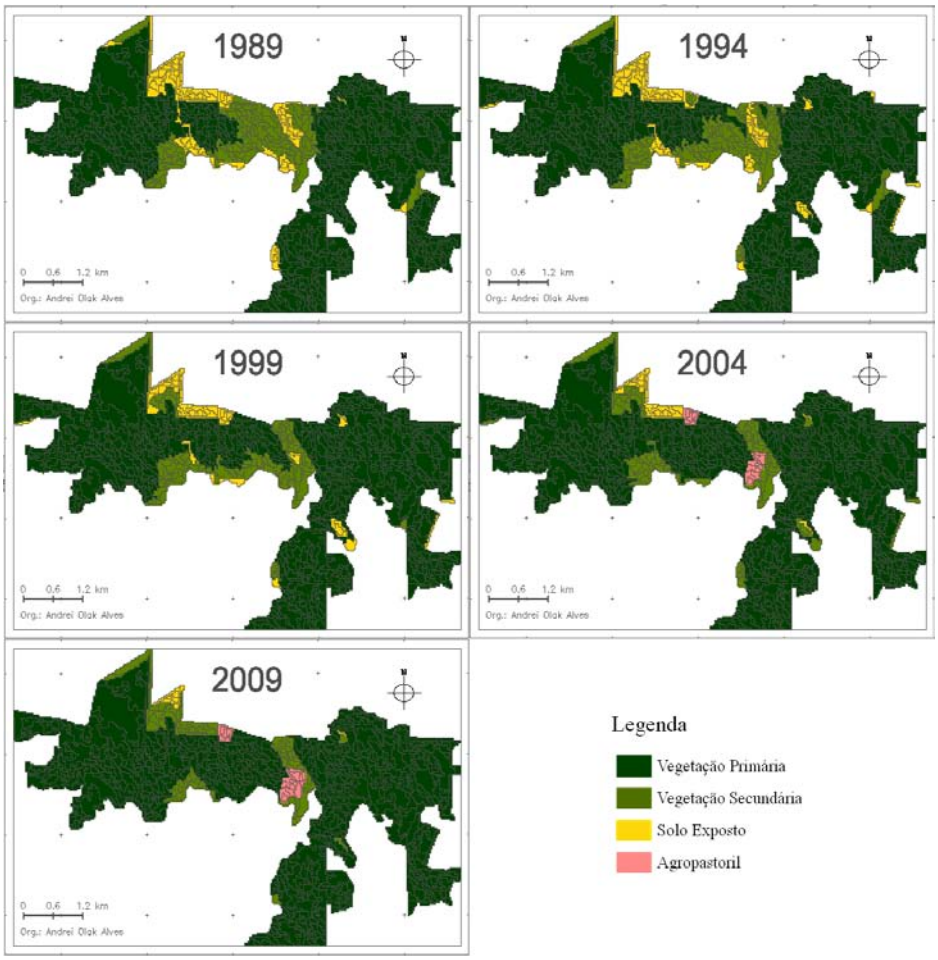

Figura 9 – Mapas temáticos de referência de uso e cobertura da terra

As classes da legenda e o número de segmentos em cada data são apresentados na Tabela 3.

Tabela 3 – Classes de cobertura da terra.

Classes	Descrição	Número 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

3.4 Classificação monotemporal

Nos procedimentos experimentais, a classificação monotemporal foi usada como uma das entradas do modelo multitemporal (vide Seção 2.2) e também como uma referência para a avaliação do desempenho da classificação multitemporal.

O classificador monotemporal utiliza o método da distância de Battacharyya para medir a separabilidade estatística entre um par de classes espectrais (Inpe, 2009a). Em outras palavras, mede a divergência entre duas populações definidas por suas distribuições de probabilidade. Assim, para cada classe de interesse, são geradas funções discriminantes relativas aos objetos. Em seguida, estas funções discriminantes são fuzzificadas, passando, a partir de então, a ser tratado como um classificador *fuzzy.* Para a comparação dos resultados da classificação mono e multitemporal, a saída do classificador de Battacharya foi defuzzificada, de forma que um objeto é associado à classe para a qual apresenta o maior grau de pertinência. Deve ser mencionado que o classificador de Battacharya requer interação do usuário através do treinamento, e se enquadra na classe de métodos supervisionados. Nesta pesquisa, as amostras correspondem a segmentos gerados pelo procedimento de segmentação.

Maiores informações sobre o método pode ser encontrado em Bhattacharyya (1943) e Comaniciu et al. (2000).

3.5 Diagrama de transição de classes

O diagrama de transição de classes representa as transições de estados de cobertura da terra em um determinado intervalo de tempo. O conhecimento das transições que podem efetivamente ocorrer em determinado intervalo de tempo é de suma importância, por reduzir a quantidade de parâmetros (possibilidades de transições de classe) a serem estimados.

Para a análise experimental, devido a diferença de possibilidades de transição de classes existentes na área de estudo em intervalos de tempo curtos e longos, fez-se necessária a elaboração dois diagramas. O primeiro corresponde às possibilidades de transição de classes para um intervalo temporal de 5 anos. O segundo, corresponde as possíveis transições para os intervalos de 10, 15 ou 20 anos.

A elaboração dos diagramas foi realizada a partir da análise da dinâmica temporal da área de estudo, nas instâncias de tempo determinadas. Em seguida, a validade dos diagramas foi conferida com base na interpretação visual das imagens através do cruzamento dos mapas temáticos. Tanto a classificação manual quanto o cruzamento dos mapas temáticos foram elaborados com o uso do software Spring 5.1.4.

A Figura 10 apresenta os mapas de dinâmica obtidos como resultado do cruzamento dos mapas temáticos de referência.

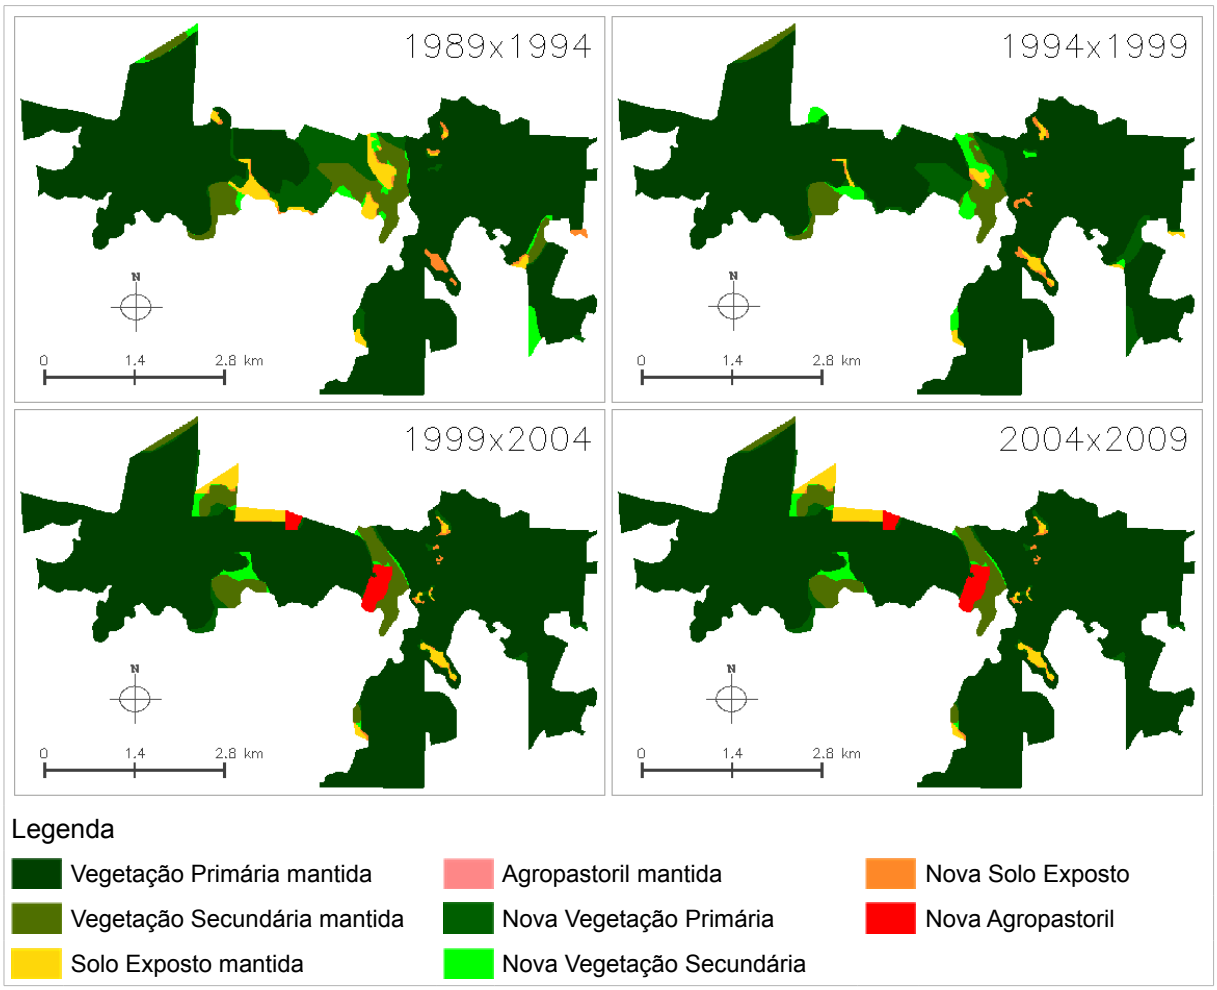

Figura 10 – Mapa da dinâmica de uso da terra da área em estudo

A geração dos mapas da dinâmica do uso da terra possibilitou, então, definir com os tipos de transições possíveis para o período analisado.

A Figura 11 apresenta o diagrama de transição de classes para uma instância de tempo de 5 anos, $\mathbf{T}^1$, onde foram identificadas 13 possibilidades de transição:

τ_{11} - Mata Primária para Mata Primária;
τ_{13} - Mata Primária para Solo Exposto;
τ_{14} - Mata Primária para Agropastoril;
τ_{22} - Mata Secundária para Mata Secundária;
τ_{21} - Mata Secundária para Mata Primária;
τ_{23} - Mata Secundária para Solo Exposto;
τ_{24} - Mata Secundária para Agropastoril;
τ_{33} - Solo Exposto para Solo Exposto;
τ_{32} - Solo Exposto para Mata Secundária;
τ_{34} - Solo Exposto para Agropastoril;
τ_{44} - Agropastoril para Agropastoril;
τ_{42} - Agropastoril para Mata Secundária;
τ_{43} - Agropastoril para Solo Exposto.

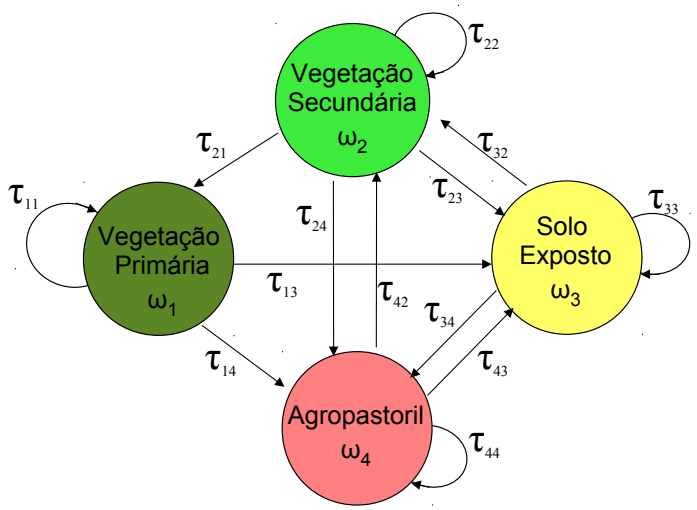

Figura 11 – Diagrama de transição de classes para $\mathbf{T}^1$

A Figura 12 apresenta o diagrama de transição de classes para instâncias de tempo de 10, 15 ou 20 anos, $\mathbf{T}^k$. Pode-se verificar que, além das 13 possibilidades de transição já identificadas no diagrama que representa $\mathbf{T}^1$, são arescentados outros três tipos de transição:

τ_{12} - Vegetação Primária para Vegetação Secundária;
τ_{31} - Solo Exposto para Vegetação Primária;
τ_{41} - Agropastoril para Vegetação Primária.

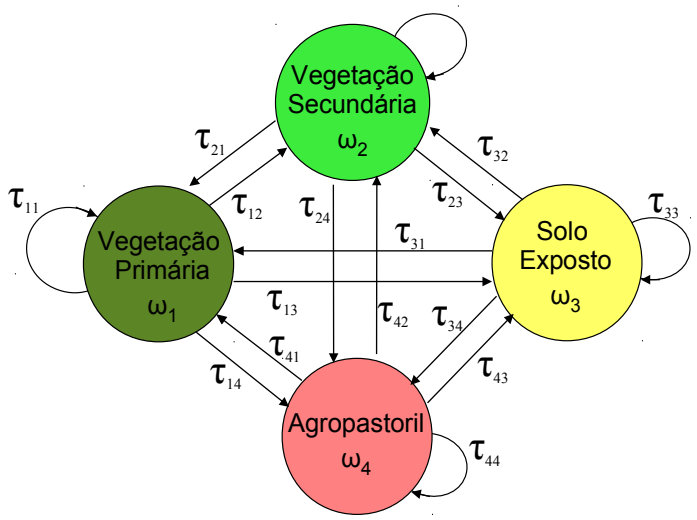

Figura 12 – Diagrama de transição de classes para $\mathbf{T}^k$

Assim, verificou-se que para intervalos de 10 anos ou mais existe a possibilidade de ocorrer qualquer tipo de transição dentre as classes identificadas.

3.6 Infraestrutura de Software

Na pesquisa foram utilizados 2 programas, o SPRING, para preparação da base de dados e criação da classificação de referência, e o MATLAB, para implementação dos classificadores, classificação das imagens e geração dos dados para avaliação dos resultados.

O software SPRING – Sistema para Processamento de Informações Georreferenciadas é um SIG (Sistema de Informação Geográfica) criado pelo INPE / DPI - Departamento de Processamento de Imagens para ambientes Windows e Linux. Dentre outras funções, o sistema possui ferramentas para processamento de imagens, análise espacial, geração de dados cadastrais, temáticos e numéricos. Basicamente, o sistema foi utilizado para criar um banco de dados espacial, registrar e recortar as imagens de sensoriamento remoto, realização a segmentação das imagens e criar, a partir dos segmentos, a classificação de referência para cada ano.

O software MATLAB é um sistema criado pela empresa *The MathWorks* e se baseia em uma linguagem de programação de alto nível e um ambiente interativo para o desenvolvimento de algoritmos, visualização de dados, análise de dados e cálculo numérico (Mathworks, 2009). Sinteticamente, o software foi utilizado para criar a base de dados inicial, para implementação dos classificadores monotemporal e multitemporais e geração dos resultados finais.

3.7 Sequência do Modelo Temporal

Tomando como base a série temporal adotada, as características da área de estudo e as classes de uso e cobertura da terra, foram calculadas matrizes de transição para intervalos de 5 anos $\mathbf{T}^1$.

A inexistência, nos anos de 1989, 1994 e 1999, de objetos da classe “Agropastoril” poderia prejudicar a estimação da matriz de transição utilizada como objeto do procedimento de extrapolação (seção 2.4). Para evitar este inconveniente, a sequência temporal utilizada nos experimentos foi invertida. Deve-se mencionar a inexistência de restrições teóricas para esta

inversão. É importante enfatizar que, como consequência da inversão da sequência temporal, a implementação dos experimentos requereu a mudança no sentido das arestas dos diagramas de transição de estados apresentados nas Figuras 11 e 12.

A partir da combinação de duas ou mais CMF baseadas **T**, foram estimadas novas matrizes para classificar as imagens de 10 ($\mathbf{T}^2$), 15 ($\mathbf{T}^3$) e 20 anos ($\mathbf{T}^4$).

Para o intervalo de 5 anos, foi possível obter quatro classificações multitemporais para os anos de 2004, 1999, 1994 e 1989, representadas na Figura 13,

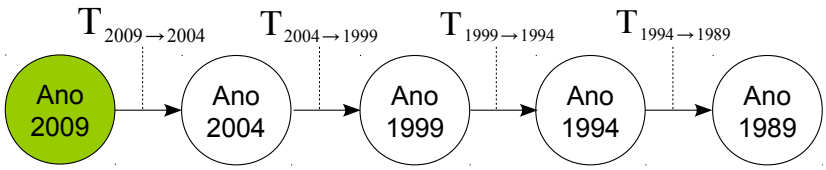

Figura 13 – Sequência do modelo temporal de 5 anos

onde:

- $\mathbf{T}_{2009\rightarrow2004}$ foi estimada a partir do par de datas 2009→2004;
- $\mathbf{T}_{2004\rightarrow1999}$ foi estimada a partir do par de datas 2004→1999;
- $\mathbf{T}_{1999\rightarrow1994}$ foi estimada a partir do par de datas 1999→1994; e
- $\mathbf{T}_{1994\rightarrow1989}$ foi estimada a partir do par de datas 1994→1989.

Para o intervalo de 10 anos, foi possível obter seis classificações multitemporais.

A Figura 14 apresenta a sequência do modelo temporal de 10 anos para as três classificações com base nas matrizes de transição estimadas diretamente para os devidos pares de datas,

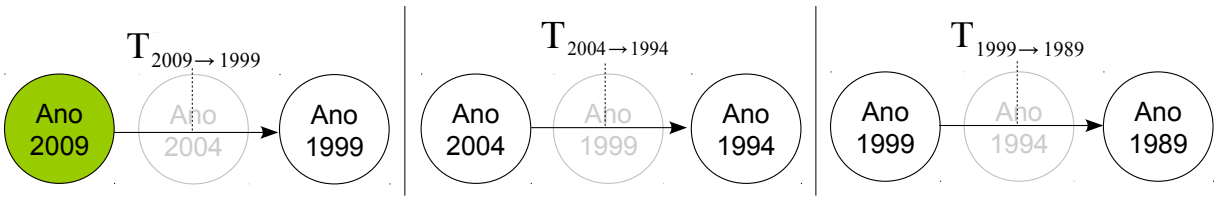

Figura 14 – Sequência do modelo temporal de 10 anos para matrizes estimadas diretamente

onde:

- $\mathbf{T}_{2009\rightarrow1999}$ foi estimada a partir do par de datas 2009→1999;
- $\mathbf{T}_{2004\rightarrow1994}$ foi estimada a partir do par de datas 2004→1994;

- $\mathbf{T}_{1999\rightarrow1989}$ foi estimada a partir do par de datas 1999→1989.

A Figura 15 apresenta a sequência do modelo temporal de 10 anos para outras três classificações com base nas matrizes de transição extrapoladas a partir da matriz de transição estimada para pares de datas de 5 anos,

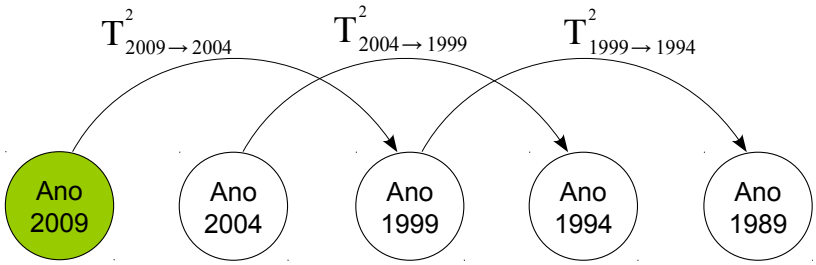

Figura 15 – Sequência do modelo temporal de 10 anos para matrizes extrapoladas

onde:

- $\mathbf{T}^2_{2009\rightarrow2004}$ representa uma matriz de transição para um intervalo de 10 anos, extrapolada a partir da matriz de transição estimada para o par de datas 2009→2004;
- $\mathbf{T}^2_{2004\rightarrow1999}$ representa uma matriz de transição para um intervalo de 10 anos, extrapolada a partir da matriz de transição estimada para o par de datas 2004→1999;
- $\mathbf{T}^2_{1999\rightarrow1994}$ representa uma matriz de transição para um intervalo de 10 anos, extrapolada a partir da matriz de transição estimada para o par de datas 1999→1994.

A Equação 9 apresenta as combinações $\mathbf{T}^2$ apresentadas na Figura 15.

$$\begin{aligned}
\mathbf{T}^2_{2009\rightarrow2004} &= \mathbf{T}_{2009\rightarrow2004} \circ \mathbf{T}_{2009\rightarrow2004} \\
\mathbf{T}^2_{2004\rightarrow1999} &= \mathbf{T}_{2004\rightarrow1999} \circ \mathbf{T}_{2004\rightarrow1999} \\
\mathbf{T}^2_{1999\rightarrow1994} &= \mathbf{T}_{1999\rightarrow1994} \circ \mathbf{T}_{1999\rightarrow1994}
\end{aligned} \tag{9}$$

Para o intervalo de 15 anos, foi possível obter quatro classificações multitemporais.

A Figura 16 apresenta a sequência do modelo temporal de 15 anos para as duas

classificações com base nas matrizes de transição estimadas diretamente para os devidos pares de datas.

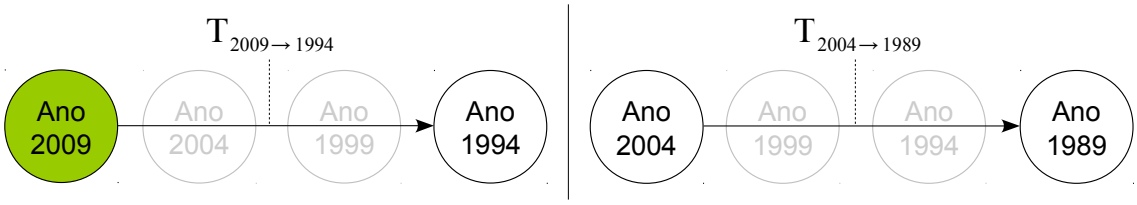

Figura 16 – Sequência do modelo temporal de 15 anos para matrizes estimadas diretamente

onde:

- $\mathbf{T}_{2009\rightarrow1994}$ foi estimada a partir do par de datas 2009→1994;
- $\mathbf{T}_{2004\rightarrow1989}$ foi estimada a partir do par de datas 2004→1989.

A Figura 17 apresenta a sequência do modelo temporal de 15 anos para as duas classificações com base nas matrizes de transição extrapoladas a partir da matriz de transição estimada para pares de datas de 5 anos,

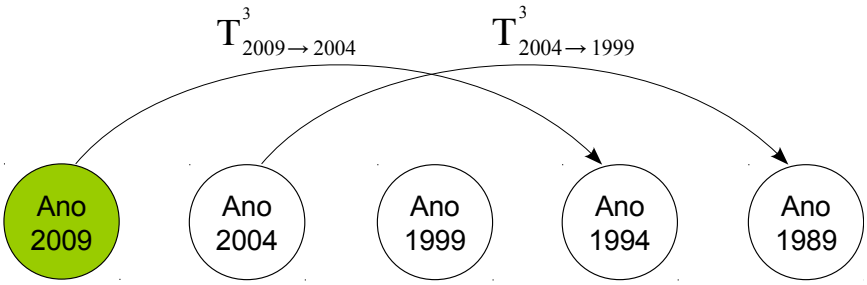

Figura 17 – Sequência do modelo temporal de 15 anos

onde:

- $\mathbf{T}^3_{2009\rightarrow2004}$ representa uma matriz de transição para um intervalo de 15 anos, extrapolada a partir da matriz de transição estimada para o par de datas 2009→2004;
- $\mathbf{T}^3_{2004\rightarrow1999}$ representa uma matriz de transição para um intervalo de 15 anos, extrapolada a partir da matriz de transição estimada para o par de datas 2004→1999.

A Equação 10 apresenta as combinações $\mathbf{T}^3$ apresentadas na Figura 17.

$$\begin{aligned} \mathbf{T}^3_{2009\rightarrow 2004} &= \mathbf{T}^2_{2009\rightarrow 2004} \circ \mathbf{T}_{2009\rightarrow 2004} \\ \mathbf{T}^3_{2004\rightarrow 1999} &= \mathbf{T}^2_{2004\rightarrow 1999} \circ \mathbf{T}_{2004\rightarrow 1999} \end{aligned} \tag{10}$$

Ainda, para o intervalo de 20 anos foi possível obter duas classificações multitemporais.

A Figura 18 apresenta a sequência do modelo temporal de 20 anos para uma classificação com base na matriz de transição estimada diretamente para o par de datas 2009→1989.

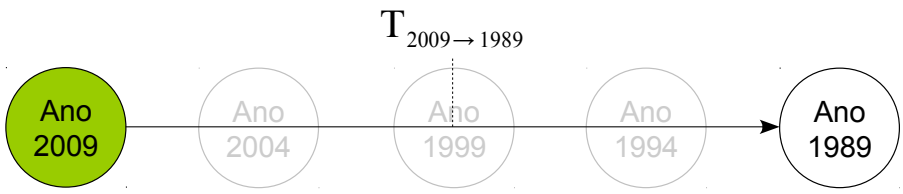

Figura 18 – Sequência do modelo temporal de 20 anos

onde:

- $\mathbf{T}_{2009\rightarrow 1989}$ foi estimada a partir do par de datas 2009→1989;

A Figura 19 apresenta a sequência do modelo temporal de 20 anos para uma classificação com base nas matrizes de transição extrapoladas a partir da matriz de transição estimada para o intervalo de 5 anos,

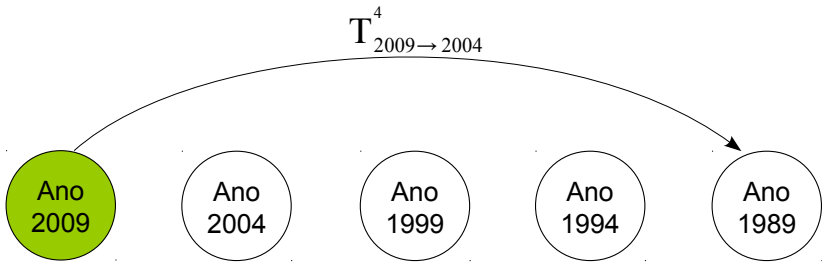

Figura 19 – Sequência do modelo temporal de 20 anos

onde:

- $T^4_{2009\rightarrow2004}$ representa uma matriz de transição para um intervalo de 20 anos, extrapolada a partir da matriz de transição estimada para o par de datas 2009→2004;

A Equação 11 apresenta a combinação das CMF para $\mathbf{T}^4$ apresentada na Figura 19,

$$\mathbf{T}^4_{2009\rightarrow2004} = \mathbf{T}^3_{2009\rightarrow2004} \circ \mathbf{T}_{2009\rightarrow2004} \tag{11}$$

Após a definição das restrições sobre as transições de classes para cada período em análise (seção 3.5) e da série temporal a ser classificada, foi possível estimar as matrizes de transição e realizar as classificações.

3.8 Modelo do protótipo experimental

Para obter os resultados de acordo com os métodos propostos, foram implementados vários programas no software Matlab.

A Figura 20 apresenta um modelo de organização dos programas que compõem o protótipo experimental, onde os itens (a), (b), (c), (d), (e) e (f) representam os principais programas e seus subprogramas.

A etapa "(a) Criação da Base de Dados" consistiu na elaboração de dois programas, o primeiro carrega e estrutura a base de dados necessária aos procedimentos posteriores e o segundo visando eliminar os polígonos de dimensão reduzida (cuja área equivale a um pequeno número de pixels) que trazem problemas na estimação dos parâmetros da distância de Bhatthacharya.

Em seguida, foram criados os programas para "(b) Seleção do Conjunto de Treinamento". Para cada rodada dos experimentos, a base de dados é dividida em dois grupos: 50% dos segmentos são utilizados no treinamento enquanto os restantes 50% dos objetos são usados para a avaliação de desempenho do método.

Ainda para a seleção do conjunto de treinamento, foi criado um subprograma para estabelecer o critério de "seleção por transição", onde os segmentos selecionados deveriam pertencer ao conjunto de transições possíveis no intervalo temporal (vide Seção 3.5), evitando

assim a queda do desempenho dos classificadores.

Para cada ano da série temporal foram realizados 200 sorteios do conjunto de treinamento e de validação, sendo que para cada sorteio o Algoritmo Genético foi executado cinco vezes.

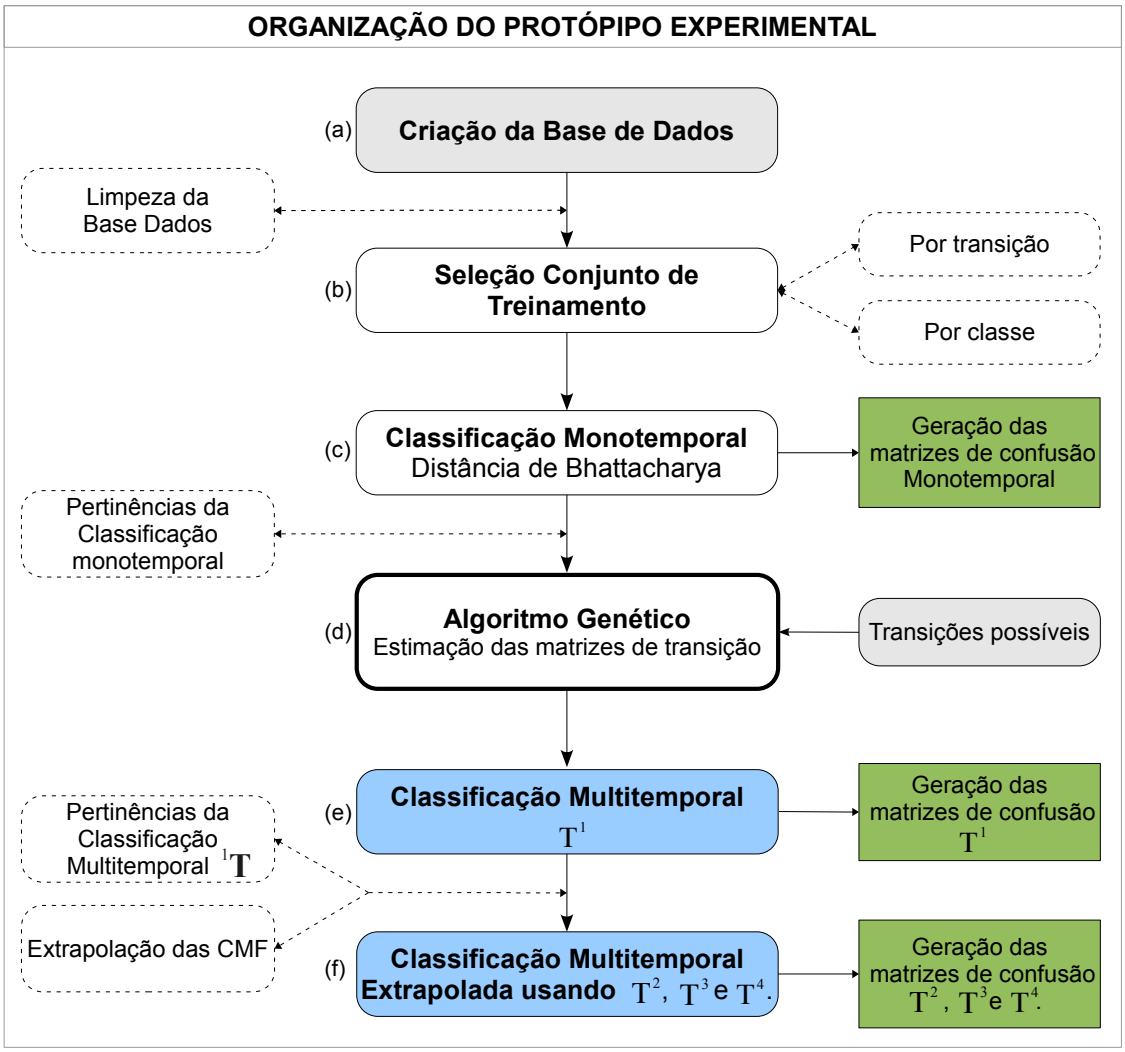

Figura 20 – Visão geral do procedimento experimental

Após a seleção do conjunto de treinamento a "(c) Classificação Monotemporal" foi obtida a partir dos programas que calcularam a distância de Bhattacharya para cada objeto a ser classificado. Nesta etapa, são geradas as matrizes de confusão para posterior avaliação da classificação monotemporal. Em seguida, os valores de decisão do classificador monotemporal são normalizados entre 0 e 1 como forma de se obter os graus de pertinência da classificação para cada objeto e utilizá-los como dado de entrada para o AG.

Para a etapa "(d) Algoritmo Genético" foram criados programas para entrada de dados,

para a definição dos valores dos parâmetros básicos do AG e das transições possíveis.

Após uma série de experimentos (cujos resultados não serão apresentados neste documento) que teve como objetivo investigar configurações alternativas para o AG, foram definidos os valores dos parâmetros do AG usado nos experimentos reportados neste trabalho:

- função objetivo – índice Kappa;
- número de genes no cromossoma – 52;
- codificação do cromossoma – binária;
- tamanho da população – 100;
- escala de aptidão – *rank*;
- função de seleção – roleta;
- função de mutação – uniforme;
- probabilidade de mutação – 0,01;
- número máximo de gerações – 100;
- indivíduos de elite – 2;
- operador de crossover – disperso (*scattered*);
- probabilidade de crossover – 0,8.

A partir da estimação das matrizes de transição pelo AG, os resultados da "(e) Classificação Multitemporal usando $\mathbf{T}^1$" são gerados fornecendo um vetor ${}^{t+k}\boldsymbol{\mu}$ que representa a classificação de um objeto no instante de tempo presente (seção 2.2). Nesta etapa os programas também calculam as matrizes de confusão das classificações usando $\mathbf{T}^1$.

Os programas da etapa "(f) Classificação Multitemporal Extrapolada usando $\mathbf{T}^k$" realizam a extrapolação das matrizes de transição **T** e classificam as imagens da instância de tempo seguinte, obtendo como resultados as matrizes de confusão das classificações $\mathbf{T}^k$.

3.9 Testes e experimentos

Na análise experimental foram realizados diversos testes com o objetivo de avaliar os programas e identificar os parâmetros mais adequados.

Os principais testes foram relacionados às etapas de treinamento, modelagem do

algoritmo genético, definição da regra de transição (*t-norm*, *s-norm*) para a classificação multitemporal, geração dos resultados e métodos de avaliação dos resultados.

Na etapa de treinamento, os resultados mais estáveis foram relacionados à seleção de 50% do conjunto de treinamento, utilizando o critério de "seleção por transição", ou seja, foram selecionados para treinamento os objetos que representavam algum tipo de transição de classe no período em análise. Com o intuito de reduzir a influência da seleção aleatória do conjunto de treinamento nos experimentos, os resultados apresentados correspondem à média de 200 sorteios dos conjuntos de treinamento e de validação.

Em relação à definição da regra de transição, foram empregados os operadores *mínimo* e máximo, respectivamente como *t-norm* e *s-norm*.

Já na definição de métodos de avaliação dos resultados, o índice Kappa se mostrou mais interessante por utilizar no cálculo de concordância informações de toda a matriz de confusão. Ainda, foram adotados a taxa de classificação por classe além dos erros de omissão e comissão com o objetivo de identificar com maior detalhe a qualidade da classificação.

3.9.1 Parâmetros testados não adotados no protótipo experimental

Alguns testes com parâmetros não utilizados na versão final do protótipo (por motivo de apresentarem resultados inferiores) serão apresentados nesta subseção para fins de esclarecimento.

Com relação à seleção do conjunto de treinamento, também foram realizados outros testes fazendo uso de 30% e 80% do total de segmentos para o treinamento. Ainda, foram avaliados diferentes quantidades de sorteios aleatórios do conjunto de treinamento, sendo que os principais testes vincularam-se a 25 e 50 sorteios. A seleção do conjunto de treinamento também foi avaliada sem a utilização de nenhum tipo de critério.

No classificador multitemporal o operador *t-norm* foi testado com o emprego do operador *produto.* No Algoritmo Genético, os principais testes se vincularam aos parâmetros da quantidade de cromossomas para a obtenção de melhores resultados. Assim, partindo de uma matriz de 13 possibilidades de transição relativa a $\mathbf{T}^1$, foram testadas cromossomas de: 13 *bits* (1 *bit* por transição), 26 *bits* (2 *bits* por transição), 39 *bits* (3 *bits* por transição), 52 *bits* (4 *bits* por transição), 65 *bits* (5 *bits* por transição), e 78 *bits* (6 *bits* por transição).

Outros testes do AG se referiram ao número de rodadas realizadas para cada sorteio do conjunto de treinamento, sendo rodadas testadas o número de 1, 3, 5 e 10 rodadas. Foi avaliado, também, o número de iterações necessárias para que o AG atingisse seu melhor resultado.

Alguns resultados preliminares obtidos com os parâmetros descritos estão disponíveis em Alves et al.(2011).

4 RESULTADOS E DISCUSSÕES

Devido à sequência de classificação apresentada na Figura 13, a análise dos resultados também foi feita na ordem inversa em relação ao fluxo normal de tempo, ou seja, do instante mais recente para o mais antigo. É importante ressaltar que, como o modelo temporal utiliza o estado da cobertura da terra na instância anterior, a primeira classificação multitemporal a ser apresentada é a de 2004.

Os resultados da Classificação Multitemporal empregando-se as CMF baseadas em **T**, $\mathbf{T}^2$, $\mathbf{T}^3$ e $\mathbf{T}^4$ são analisados ano a ano e comparados com os da classificação monotemporal correspondente. Conforme citado anteriormente, **T** corresponde a um intervalo de 5 anos, enquanto $\mathbf{T}^2$**,** $\mathbf{T}^3$ **e** $\mathbf{T}^4$, correspondem respectivamente aos intervalos de 10, 15 e 20 anos. Deve-se ressaltar que a alternativa para a obtenção direta de $\mathbf{T}^2$**,** $\mathbf{T}^3$ **e** $\mathbf{T}^4$ é a extrapolação, e que as Equações 9, 10 e 11 apresentadas na seção 3.7 detalham as combinações de matrizes de transição empregadas. Ambas alternativas são analisadas nos experimentos.

Seguindo a sequência temporal utilizada nos experimentos, as subseções a seguir apresentam os resultados para os dados de 2004, 1999, 1994, 1989. Por fim, a última seção sintetiza a análise das Classificações Multitemporais. Posteriormente, a espacialização das taxas de acerto é analisada, considerando, para cada data, todos os experimentos de classificação multitemporal realizados.

As avaliações das classificações foram realizadas com base nos seguintes dados estatísticos: Matriz de Confusão da classificação de Teste (classificação de validação), Taxas de Classificação por Classe, Erros de Omissão (EO) e Erros de Comissão (EC) e, por fim, do índice Kappa.

4.1 Classificação em 2004

A única classificação multitemporal da imagem de 2004 possível de ser obtida utiliza uma matriz de transição para um intervalo de 5 anos, estimada a partir dos pares de datas 2009→2004, $\mathbf{T}_{2009\rightarrow2004}$.

As Tabelas 4 e 5 apresentam, respectivamente, os resultados obtidos na classificação

do conjunto de teste pelos classificadores monotemporal e multitemporal. É importante lembrar que os valores das matrizes não correspondem a números inteiros porque representam a média de 200 experimentos realizados, conforme apresentado na seção 2.3.

Por uma breve análise de ambas matrizes de confusão, pode-se verificar que o classificador multitemporal baseado em $\mathbf{T}_{2009\rightarrow2004}$ apresentou menor confusão e melhores resultados na classificação. A seguir, os dados da tabela serão analisados individualmente com o objetivo de verificar o desempenho do classificador multitemporal e o comportamento dos classificadores por classe a fim de detalhar a análise.

Tabela 4 – Resultados da classificação Monotemporal de Teste, para 2004

Matriz de Confusão					**Erros de Comissão**	**Kappa**
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**239,59**	6,23	0,52	1,15	3,2%	
Vegetação Secundária	24,3	**27,53**	1,34	0,42	48,6%	
Solo Exposto	1,46	2,09	**8,27**	2,17	40,9%	
Agropastoril	0,94	3,25	2,13	**4,23**	59,9%	**0,60**
Erros de Omissão	10,0%	29,6%	32,6%	46,9%	14,1%	
Taxa de classificação por classe	90,0%	70,4%	67,4%	53,1%	Média 70,2%	

Tabela 5 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}_{2009\rightarrow2004}$, para 2004

Matriz de Confusão					**Erros de Comissão**	**Kappa**
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**262,91**	8,06	0,09	0,13	3,0%	
Vegetação Secundária	3,38	**27,61**	2,06	0,76	18,3%	
Solo Exposto	0	2,27	**9,87**	0,04	18,9%	
Agropastoril	0	1,17	0,25	**7,04**	16,7%	**0,82**
Erros de Omissão	1,3%	29,4%	19,5%	11,6%	5,6%	
Taxa de classificação por classe	98,7%	70,6%	80,5%	88,4%	Média 84,6%	

Na Figura 21 é possível visualizar os resultados das taxas de classificação por classe, apresentados nas Tabelas 4 e 5. Para todas as classes o resultado apresentado pelo classificador multitemporal foi superior, tendo sido obtido um ganho de 8,7% para a classe Vegetação Primária, 0,2% para Vegetação Secundária, 9,9% para Solo Exposto e 35,3% para a

classe Agropastoril.

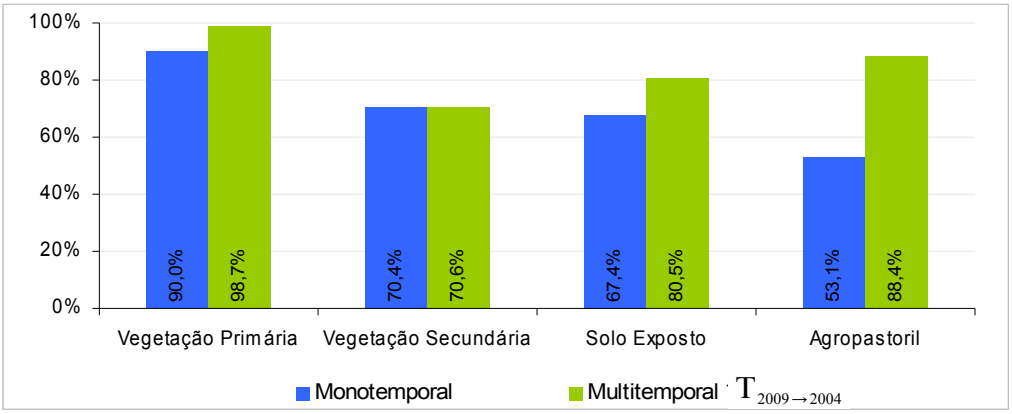

Figura 21 – Desempenho das classificações por classe em 2004.

Nos gráficos da Figura 22, que se refere ao desempenho na classificação dos conjuntos de treinamento e de teste, é possível identificar que a classificação multitemporal apresentou desempenho superior, tanto no treinamento quanto no teste.

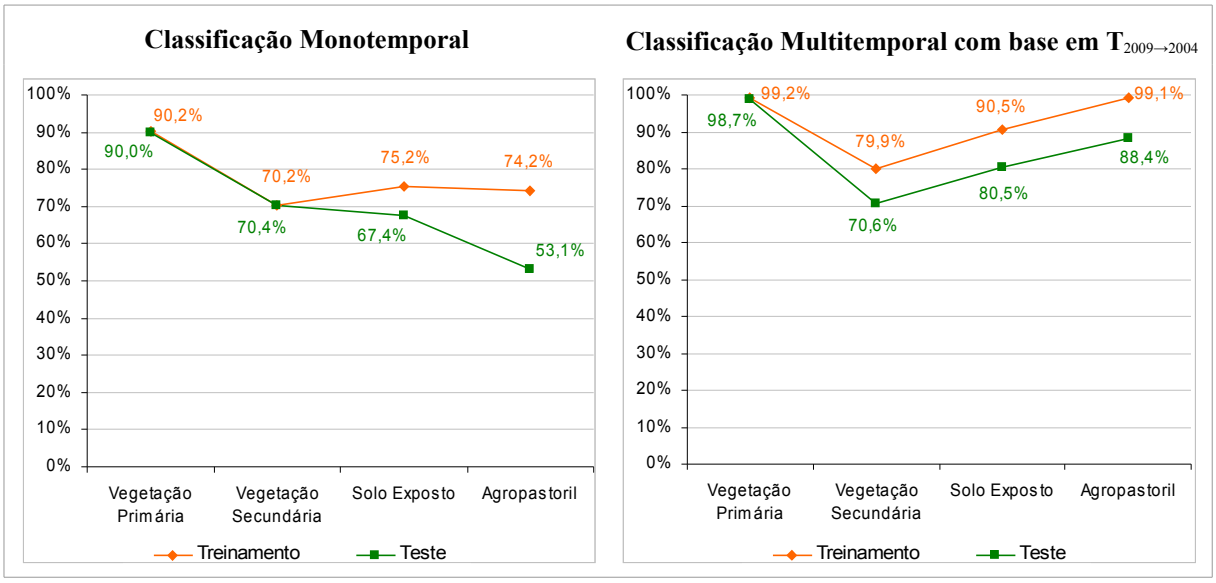

Figura 22 – Taxas de classificação para Treinamento e Teste em 2004

Para o classificador monotemporal as classes Vegetação Primária e Secundária apresentaram taxas de classificação com valores muito próximos. Na classe Vegetação Primária, as taxas de treinamento e teste foram, respectivamente, 90,2% e 90,0%; já para Vegetação Secundária, estes valores foram 70,2% e 70,4%. Para as demais, verifica-se que a classe Solo Exposto apresentou queda de 7,8% e a Agropastoril queda de 21,1%, em relação

ao treinamento.

Para o classificador monotemporal, as classes Vegetação Primária e Secundária apresentaram taxas de classificação com valores próximos. Para o classificador multitemporal, as classes Solo Exposto e Agropastoril apresentam ganhos significativos da taxa de acerto para o conjunto de treinamento em relação ao classificador monotemporal.

A comparação do EO e do EC é apresentada na Figura 23. Para o classificador monotemporal, pode-se perceber que os EO da classe Vegetação Primária foi a que apresentou menor valor. Os EC também foram significativos para as classes Vegetação Secundária, Solo Exposto e Agropastoril, o que explica a queda significativa dos resultados do classificador monotemporal apresentada na Figura 21.

Nota-se que os EO e EC do classificador multitemporal é menor do que o monotemporal, demonstrando sua superioridade. Enquanto a classificação monotemporal apresentou maiores EC, evidenciando que muitos pixels classificados como Vegetação Secundária, Solo Exposto e Agropastoril estavam classificados erradamente, os valores da classificação multitemporal são menores.

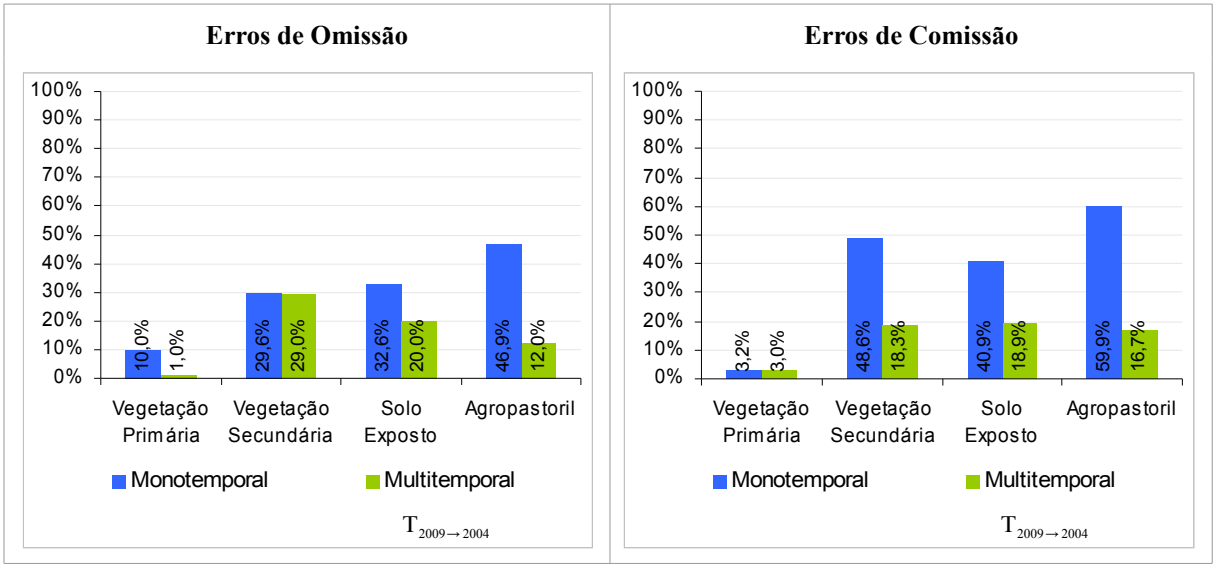

Figura 23 – Erros de Omissão e Comissão das classificações de Teste em 2004

Em se tratando apenas da classificação multitemporal, para Vegetação Primária pode-se notar que tanto o Erro de Comissão (1,3%) quanto de Omissão (3%) foram pequenos.

Já a classe Vegetação Secundária apresentou um EO de 29,4%, com expressiva confusão espectral. O EC também foi significativo, 18,3%.

Para a classe Solo Exposto pode-se notar um EO de 19,5%, causado principalmente

pela confusão com a classe Vegetação Secundária. O EC foi o mais alto de todas as classes, 18,9%.

Por fim, a classe Agropastoril apresentou EO de 11,6% e um EC de 16,7%, novamente evidenciando a melhoria da tomada de decisão do classificador quando comparada à classificação monotemporal. Da mesma forma que a classe Solo Exposto, a principal confusão se deu por conta da classe Vegetação Secundária.

A Figura 24 apresenta o índice Kappa obtido a partir das matrizes de confusão das classificações em 2004. Enquanto a classificação monotemporal atingiu índice de 0,60, a multitemporal atingiu um índice de 0,82, demonstrando um ganho significativo de 0,22 pontos.

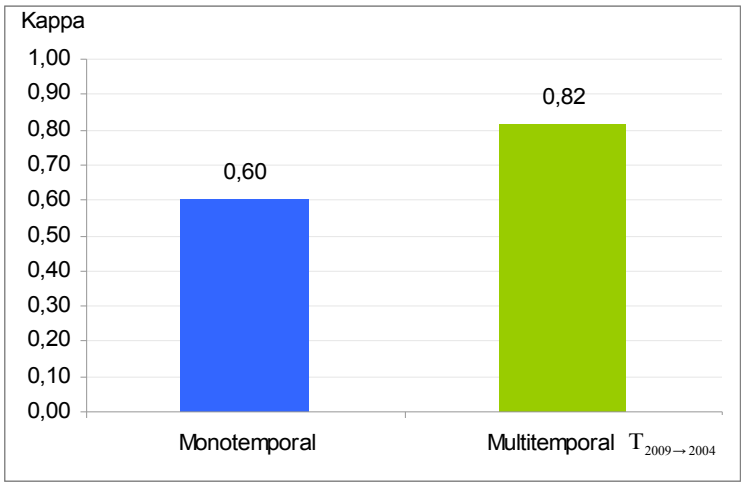

Figura 24 – Desempenho global das classificações em 2004

4.2 Classificação em 1999

Para 1999 foi possível obter três classificações multitemporais, a primeira com base em $\mathbf{T}_{2004 \rightarrow 1999}$, a segunda com base em uma matriz estimada $\mathbf{T}_{2009 \rightarrow 1999}$ e a terceira com base em uma matriz extrapolada $\mathbf{T}^2_{2009 \rightarrow 2004}$ (vide seção 3.7 para maiores detalhes).

As tabelas 6, 7, 8 e 9 apresentam os resultados obtidos pela classificação de Teste dos classificadores monotemporal e multitemporais. Devido à ausência da classe Agropastoril nos dados de referência de 1999, a respectiva coluna, nas anteriormente mencionadas tabelas, encontrar-se zerada.

Tabela 6 – Resultados da classificação Monotemporal de Teste, para 1999

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**239,27**	16,49	1,92	0	7,1%	
Vegetação Secundária	13,48	**18,38**	6,25	0	51,8%	
Solo Exposto	3,25	6,04	**18,18**	0	33,8%	
Agropastoril	0,00	0,47	0,54	**0**	100,0%	**0,57**
Erros de Omissão	6,5%	55,6%	32,4%	0	14,9%	
Taxa de classificação por classe	93,5%	44,4%	67,6%	0	Média 68,5%	

Tabela 7 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}_{2004\rightarrow1999}$, para 1999

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**253,67**	9,45	0,23	0	3,7%	
Vegetação Secundária	2,06	**27,37**	6,58	0	24,0%	
Solo Exposto	0,27	4,16	**19,79**	0	18,3%	
Agropastoril	0	0,40	0,29	**0**	100,0%	**0,79**
Erros de Omissão	0,9%	33,9%	26,4%	0	7,2%	
Taxa de classificação por classe	99,1%	66,1%	73,6%	0	Média 79,6%	

Tabela 8 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}_{2009\rightarrow1999}$, para 1999

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**252,79**	12,23	1,74	0	5,0%	
Vegetação Secundária	2,02	**21,89**	7,12	0	29,0%	
Solo Exposto	1,75	6,51	**17,71**	0	32,0%	
Agropastoril	0,01	0,49	0,26	**0**	100,0%	**0,70**
Erros de Omissão	1,5%	46,8	34,0%	0	10,0%	
Taxa de classificação por classe	98,5%	53,2%	66,0%	0	Média 72,57%	

Tabela 9 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}^2_{2009\rightarrow2004}$, para 1999

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**254,29**	15,80	4,20	0	7,3%	
Vegetação Secundária	1,91	**21,14**	8,37	0	32,7%	
Solo Exposto	0,46	4,31	**14,50**	0	24,7%	
Agropastoril	0,00	0,38	0,25	**0**	100,0%	**0,65**
Erros de Omissão	0,9%	49,2%	46,9%	0	11,0%	
Taxa de classificação por classe	99,1%	50,8%	53,1%	0	Média 67,65%	

A média de segmentos atribuídos erroneamente à classe Agropastoril é próxima de zero, contudo, a ausência de elementos desta classe nos dados de referência faz com que o Erro de Comissão para a classe Agropastoril atinja o valor de 100%. Por conta da ausência de elementos desta classe nos dados de referência, as análises que se seguem omitem esta classe.

Na Figura 25, é possível visualizar as taxas de classificação por classe apresentadas nas tabelas anteriores.

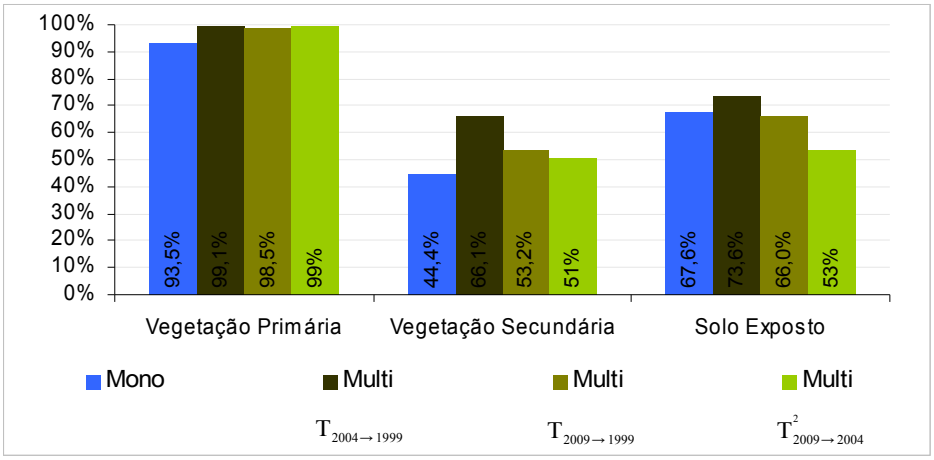

Figura 25 – Desempenho das classificações por classe em 1999

Para todas as classes os resultados apresentados pelo classificador multitemporal com base em $\mathbf{T}_{2004\rightarrow1999}$ foi superior aos do monotemporal, com acréscimo de 5,6% para Vegetação Primária, 21,7% para Vegetação Secundária e 6,0% para Solo Exposto. Já classificador multitemporal com base em $\mathbf{T}_{2009\rightarrow1999}$ apresentou melhor desempenho para as classes Vegetação Primária (ganho de 5,0%) e Secundária (ganho de 8,8%) e queda de 1,6% para

classe Solo Exposto. O classificador multitemporal com base na matriz extrapolada $\mathbf{T}^2_{2009\rightarrow2004}$ também apresentou resultados superiores nas classes Vegetação Primária (ganho de 5,6%) e Vegetação Secundária (ganho de 6,6%), com uma queda mais significativa na classe Solo Exposto, 14,5%, em relação ao monotemporal.

A partir da Figura 26 é possível realizar uma comparação entre os resultados das classificações dos conjuntos de treinamento e de teste para o ano de 1999.

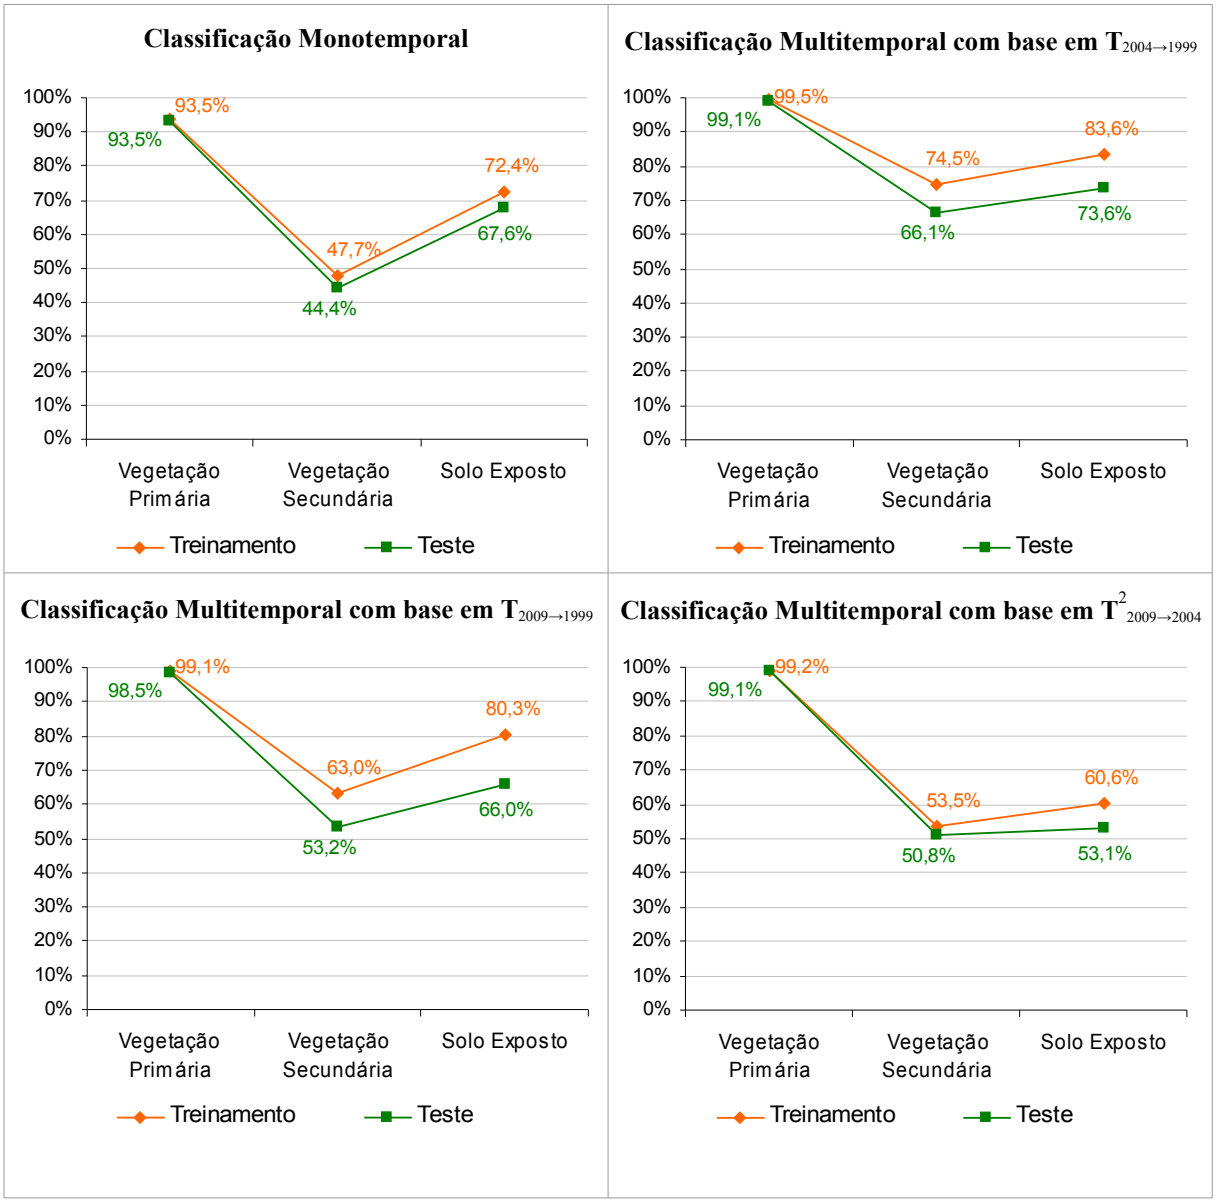

Figura 26 – Taxas de classificação para Treinamento e Teste em 1999.

Pelos gráficos percebe-se a existência de uma tendência onde a classificação de Teste reflete o Treinamento.

Os resultados com base em $\mathbf{T}_{2004\rightarrow1999}$ mostraram desempenho superior para todas as classes, cabendo destacar que o uso de um modelo de transformação temporal melhorou significativamente os resultados para a classe Vegetação Secundária, com um ganho de 21,7%, para o conjunto de teste em relação à monotemporal.

Os resultados com base em $\mathbf{T}_{2009\rightarrow1999}$ também foram superiores aos da classificação monotemporal para todas as classes, com destaque para a classe Solo Exposto, onde a taxa de classificação foi superior, também, aos das outras classificações multitemporais.

A classificação com base em $\mathbf{T}^2_{2009\rightarrow2004}$ apresentou melhor desempenho para as classes Vegetação Primária e Secundária. Em contrapartida, para a classe Solo Exposto existiu uma queda expressiva, de 14,5% para Teste.

A Figura 27 apresenta os Erros de Omissão e Comissão presentes nas tabelas 6, 7, 8 e 9, onde é possível verificar com maior detalhe a confusão entre as classes para ambas classificações.

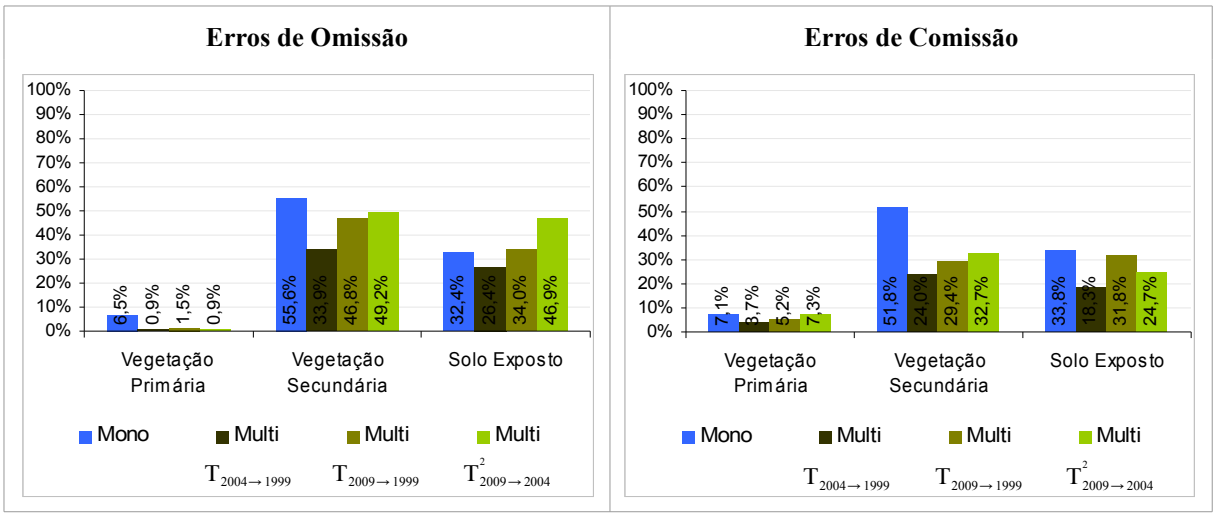

Figura 27 – Erros de Omissão e Comissão das classificações de Teste em 1999.

Pode-se verificar que a classificação multitemporal com base em $\mathbf{T}_{2004\rightarrow1999}$ apresentou as menores taxas de EO e EC tanto em relação a classificação monotemporal como das multitemporais, indicando menor confusão para todas as classes e o melhor desempenho da classificação. Já a classificação com base na matriz de transição extrapolada $\mathbf{T}^2_{2009\rightarrow2004}$ foi a que apresentou os maiores erros entre as classificações multitemporais, mas ainda com desempenho superior à monotemporal.

Para a classe Vegetação Primária os classificadores $\mathbf{T}_{2004\rightarrow1999}$, $\mathbf{T}_{2009\rightarrow1999}$ e $\mathbf{T}^2_{2009\rightarrow2004}$

apresentaram baixos valores de EO, indicando que foram poucos os segmentos da classe Vegetação Primária classificados equivocadamente. Já nos EC, as classificações com base em $\mathbf{T}_{2004\rightarrow1999}$ e $\mathbf{T}_{2009\rightarrow1999}$ foram melhores do que a monotemporal.

Para Vegetação Secundária percebe-se o incremento dos erros nos resultados da classificação multitemporal, a medida que informação do "passado" provém de um tempo mais distante. Ainda assim, o desempenho dos classificadores multitemporais em relação ao monotemporal foi sempre superior à classificação monotemporal. As reduções nos EO com base em $\mathbf{T}_{2004\rightarrow1999}$, $\mathbf{T}_{2009\rightarrow1999}$ e $\mathbf{T}^2_{2009\rightarrow2004}$ foram, respectivamente, de 21,7%, 8,8% e 6,4%, enquanto, para os EC foram de 27,8%, 31,1% e 19,1%.

Por fim, para a classe Solo Exposto, os EO com base em $\mathbf{T}_{2009\rightarrow1999}$ e $\mathbf{T}^2_{2009\rightarrow2004}$ foram maiores do que na classificação monotemporal, desempenho somente superado por $\mathbf{T}_{2004\rightarrow1999}$. Entretanto, para EC, todas as classificações multitemporais apresentaram redução do erro em comparação a monotemporal.

Para concluir a análise do ano de 1999, a Figura 28 apresenta o desempenho global das classificações a partir dos resultados do índice Kappa.

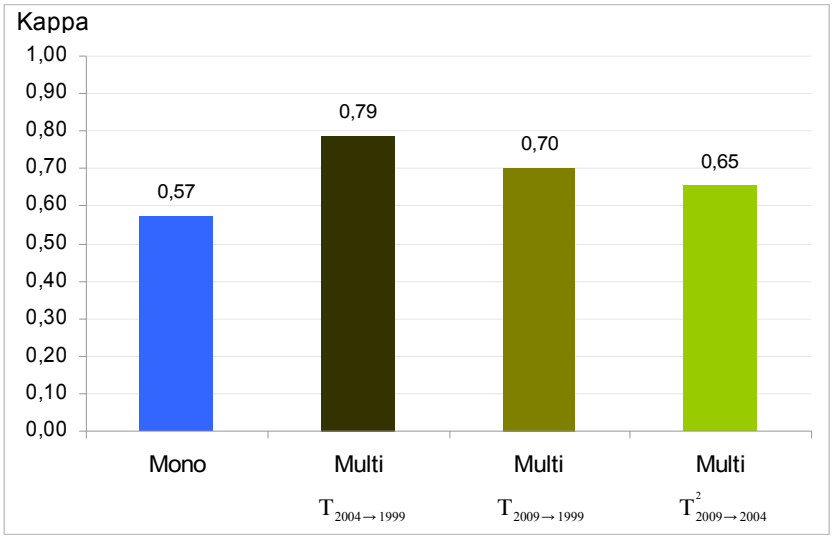

Figura 28 – Desempenho global das classificações em 1999.

Quando comparado com a classificação monotemporal, as classificações com base em $\mathbf{T}_{2004\rightarrow1999}$, $\mathbf{T}_{2009\rightarrow1999}$ e $\mathbf{T}^2_{2009\rightarrow2004}$ apresentaram, respectivamente, ganhos de 0,22, 0,13 e 0,08 pontos no índice Kappa. _Isso demonstra que a classificação com base na matriz de transição $\mathbf{T}_{2004\rightarrow1999}$, utilizada na modelagem do conhecimento temporal para intervalo de tempo curto,

apresentou resultados melhores do que a classificação com base em $\mathbf{T}_{2009\rightarrow1999}$, onde a matriz estimada modela o conhecimento temporal para intervalo de tempo longo. Ainda, que a classificação com base em $\mathbf{T}^2_{2009\rightarrow2004}$, onde a matriz extrapolada simula a modelagem do conhecimento temporal para intervalo de tempo longo, gerou resultados inferiores às outras duas classificações multitemporais.

Assim, pode-se observar que no ano de 1999 todas classificações multitemporais apresentaram desempenho global superior ao da monotemporal. Este desempenho pode ser observado tanto pelo índice Kappa quanto nas taxas de classificação por classe.

4.3 Classificação em 1994

Para 1994 foram obtidas cinco classificações multitemporais, com base em:

- $\mathbf{T}_{1999\rightarrow1994}$, estimada a partir do par de datas 1999→1994;
- $\mathbf{T}_{2004\rightarrow1994,}$ estimada a partir do par de datas 2004→1994;
- $\mathbf{T}^2_{2004\rightarrow1999,}$ que representa uma matriz de transição para um intervalo de 10 anos, extrapolada a partir da matriz de transição estimada para o par de datas 2004→1999;
- $\mathbf{T}_{2009\rightarrow1994,}$ estimada a partir do par de datas 2009→1994; e
- $\mathbf{T}^3_{2009\rightarrow2004,}$ que representa uma matriz de transição para um intervalo de 15 anos, extrapolada a partir da matriz de transição estimada para o par de datas 2009→2004.

As tabelas 10, 11, 12, 13, 14 e 15 apresentam os resultados das classificações de Teste dos classificadores monotemporal e multitemporal.

Da mesma forma que para o ano de 1999, em 1994 não existe ocorrência de cobertura da classe Agropastoril para a área de estudo. Portanto, esta classe não será incluída na análise a seguir.

Tabela 10 – Resultados da classificação Monotemporal de Teste, para 1994

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**199,96**	11,70	0,18	0	5,6%	**0,60**
Vegetação Secundária	37,89	**32,27**	8,82	0	59,1%	
Solo Exposto	2,07	1,41	**31,29**	0	10,0%	
Agropastoril	0	0	0,03	**0**	100,0%	
Erros de Omissão	16,7%	28,9%	22,4%	0	19,1%	
Taxa de classificação por classe	83,3%	71,1%	77,6%	0	Média 77,3%	

Tabela 11 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}_{1999\rightarrow1994}$, para 1994

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**237,72**	17,71	0,71	0	7,2%	
Vegetação Secundária	1,42	**25,13**	3,22	0	15,6%	
Solo Exposto	0,78	2,54	**36,29**	0	8,4%	
Agropastoril	0	0	0,11	**0**	100,0%	**0,79**
Erros de Omissão	0,9%	44,6%	10,0%	0	8,1%	
Taxa de classificação por classe	99,1%	55,4%	90,0%	0	Média 81,5%	

Tabela 12 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}_{2004\rightarrow1994}$, para 1994

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**232,35**	24,37	0,45	0	10,0%	
Vegetação Secundária	5,11	**17,59**	3,92	0	34,0%	
Solo Exposto	0,85	3,63	**35,86**	0	11,0%	
Agropastoril	0	0	0,11	**0**	100,0%	**0,70**
Erros de Omissão	3,0%	61,0%	11,0%	0	12,0%	
Taxa de classificação por classe	97,5%	38,6%	88,9%	0	Média 75,0%	

Tabela 13 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}^2_{2004\rightarrow1999}$, para 1994

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**232,63**	24,63	0,39	0	9,7%	
Vegetação Secundária	5,20	**19,65**	8,18	0	40,5%	
Solo Exposto	0,81	1,73	**31,02**	0	7,5%	
Agropastoril	0,00	0,00	0,04	**0**	100,0%	**0,67**
Erros de Omissão	2,5%	57,3%	21,7%	0	12,6%	
Taxa de classificação por classe	97,5%	42,7%	78,3%	0	Média 72,8%	

Tabela 14 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}_{2009\rightarrow1994}$, para 1994

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**229,99**	25,35	0,44	0	10,0%	
Vegetação Secundária	6,93	**16,24**	5,72	0	44,0%	
Solo Exposto	1,71	3,88	**33,49**	0	14,0%	
Agropastoril	0	0	0,09	**0**	100,0%	**0,65**
Erros de Omissão	4,0%	64,0%	16,0%	0	14,0%	
Taxa de classificação por classe	96,4%	35,7%	84,3%	0	Média 72,1%	

Tabela 15 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}^3_{2009\rightarrow2004}$, para 1994

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**236,13**	27,92	2,56	0	11,4%	
Vegetação Secundária	3,33	**16,29**	9,21	0	43,5%	
Solo Exposto	0,48	**1,14**	**28,49**	0	5,3%	
Agropastoril	0,00	0,00	0,09	**0**	100,0%	**0,63**
Erros de Omissão	1,6%	64,1%	29,4%	0	13,7%	
Taxa de classificação por classe	98,4%	35,9%	70,6%	0	Média 68,3%	

Na Figura 29 é possível visualizar os resultados das taxas de classificação por classe apresentados nas tabelas anteriores.

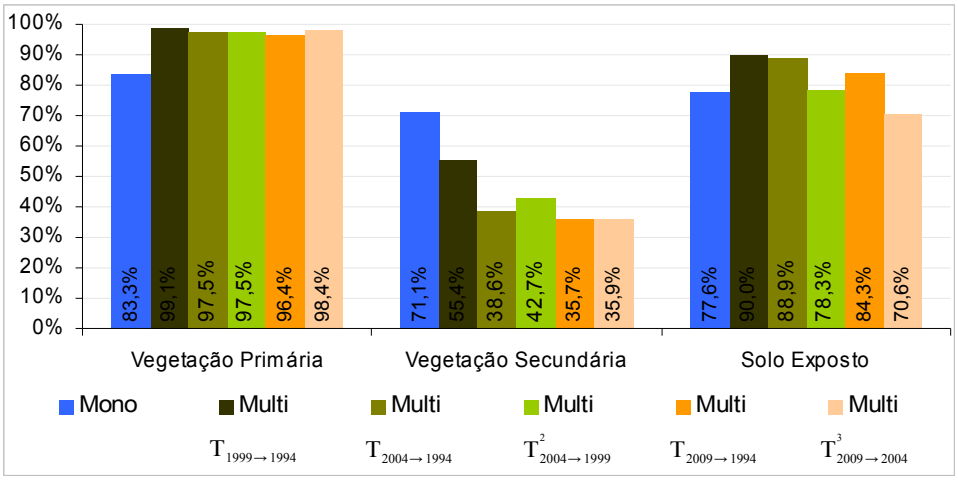

Figura 29 – Desempenho das classificações por classe em 1994

Para a classe Vegetação Primária todas as classificações multitemporais apresentaram resultados superiores aos da classificação monotemporal, sendo que o ganho mais significativo foi de 15,8% ($\mathbf{T}_{1999\rightarrow1994}$) e o menor ganho foi de 13,1% ($\mathbf{T}_{2009\rightarrow1994}$) em relação as taxas da classificação monotemporal.

Já para a classe Vegetação Secundária, todas as classificações multitemporais apresentaram queda nos resultados, sendo que a maior queda foi de 35,2% ($\mathbf{T}^{3}_{2009\rightarrow2004}$) e a menor de 15,7% ($\mathbf{T}_{1999\rightarrow1994}$).

Na classe Solo Exposto apenas a classificação com base em $\mathbf{T}^{3}_{2009\rightarrow2004}$ apresentou resultados inferiores aos da classificação monotemporal (queda de 7,0%).

Os resultados acima podem ser melhor detalhados com a análise das classificações de Treinamento e Teste apresentados na Figura 30.

As taxas de classificação por classe para Treinamento e Teste mostram que a classificação monotemporal apresentou considerada estabilidade nos resultados. Já nas classificações multitemporais é possível observar que a queda de desempenho para a classe Vegetação Secundária ocorre tanto para o conjunto de treinamento quanto teste. Ainda, pode-se verificar que, em todos os experimentos, os valores da taxa de classificação tanto para treinamento quanto para teste foram muito similares.

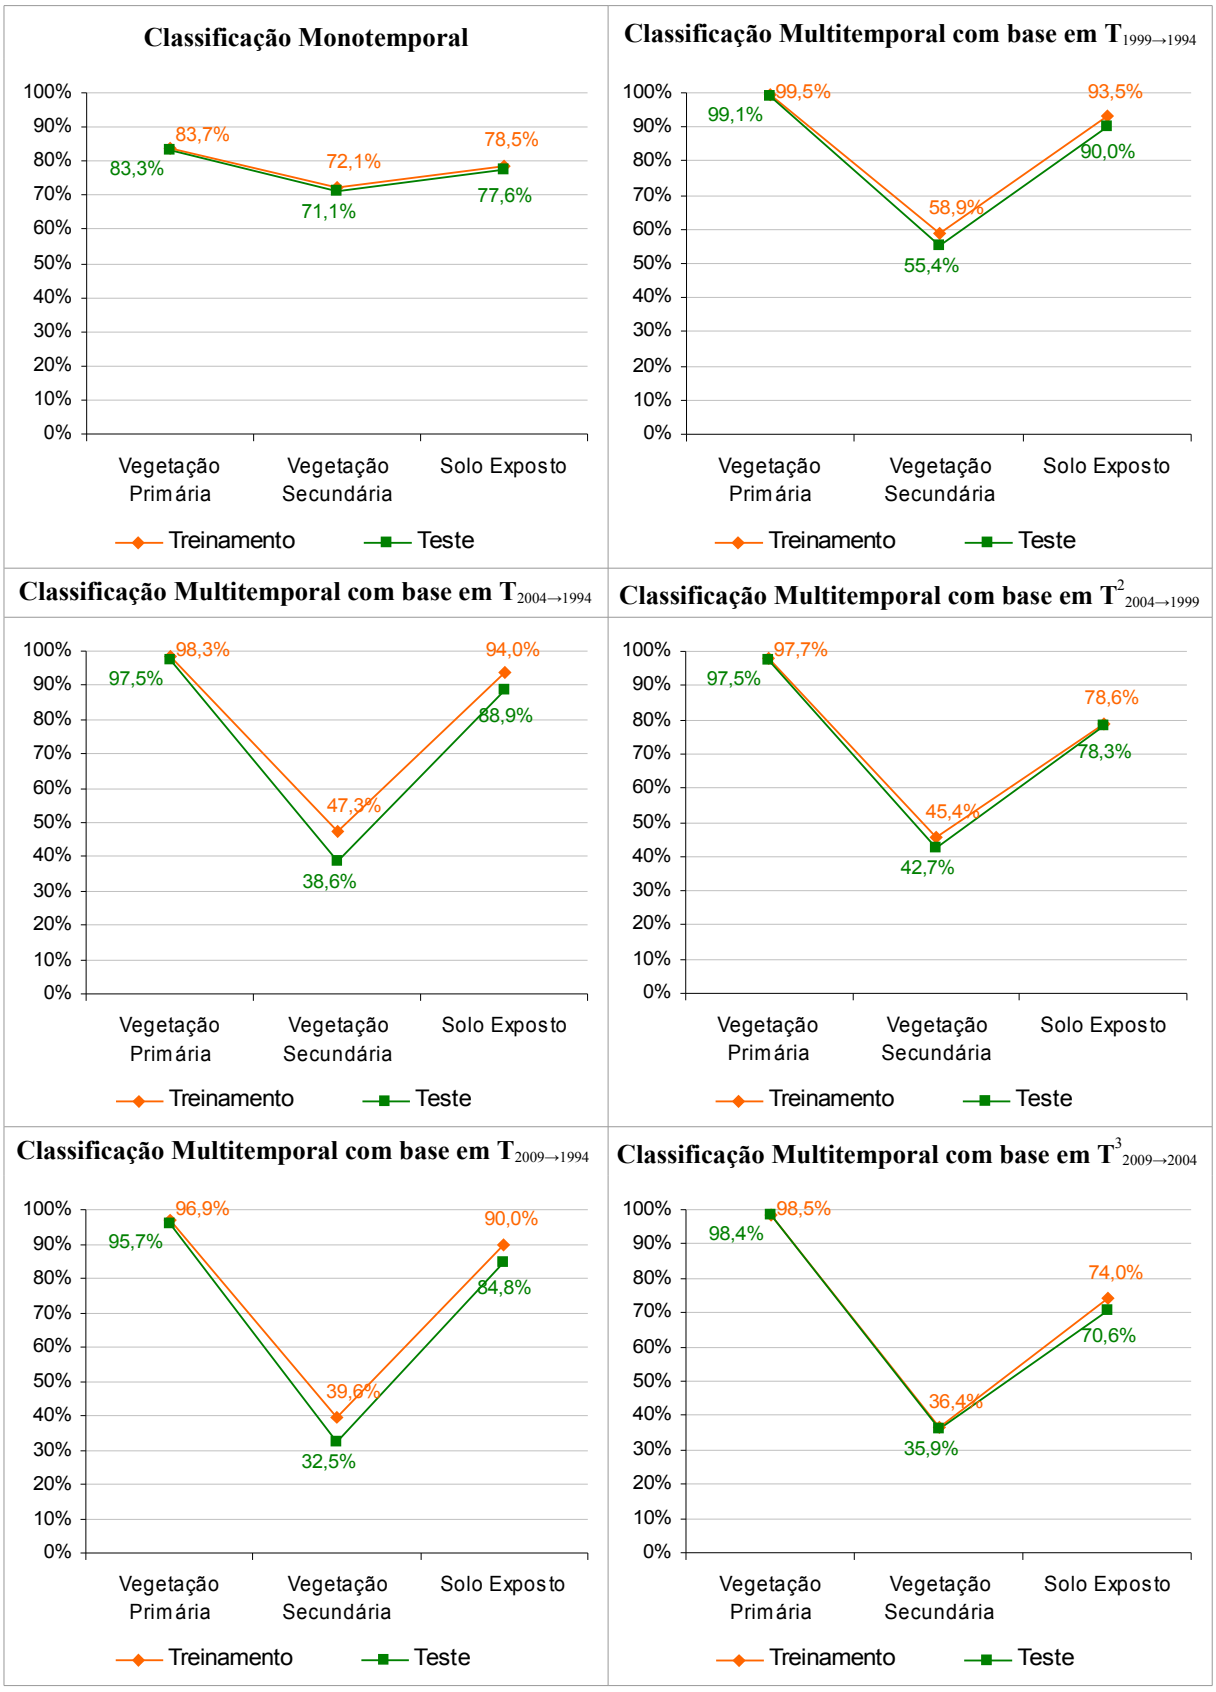

Figura 30 – Taxas de classificação para Treinamento e Teste em 1994.

A Figura 31 apresenta os Erros de Omissão e Comissão das classificações.

Para a classe Vegetação Primária, os EO das classificações multitemporais foram significativamente menores em comparação com a monotemporal, sendo que a redução do erro mais evidente foi para a classificação com base em $\mathbf{T}_{1999\rightarrow1994}$, onde a diferença de 15,8% representou uma redução de 18 vezes. Em contrapartida, os EC foram maires do que a classificação monotemporal.

É possível perceber, ainda, que a classe Vegetação Secundária apresentou aumento significativo dos EO, que são, principalmente, gerados por uma confusão com a classe Vegetação Primária. Já os EC das classificações multitemporais apresentaram redução para esta classe.

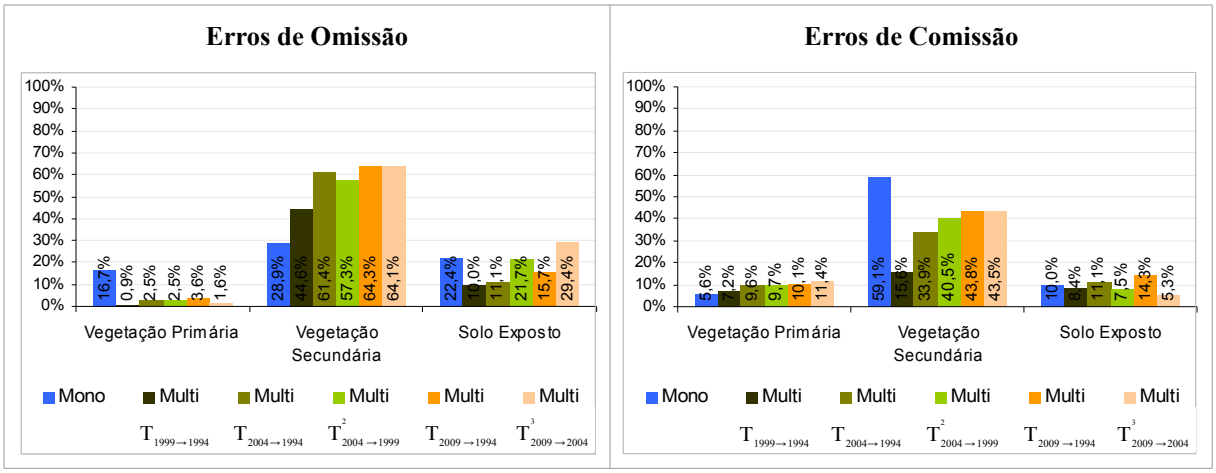

Figura 31 – Erros de Omissão e Comissão das classificações de Teste em 1994.

Para a classe Solo Exposto, os EO e EC não foram tão significativos quanto da classe Vegetação Secundaria, e os resultados mostram que os erros variaram de acordo com o conhecimento temporal utilizado nas classificações.

Finalizando a análise de 1994, na Figura 32, é possível verificar o desempenho global das classificações obtido a partir do índice Kappa.

Apesar do baixo desempenho apresentado para a classe Vegetação Secundária, pode-se verificar que o desempenho global dos classificadores multitemporais sempre foi superior ao monotemporal.

O ganho no desempenho das classificações com base em $\mathbf{T}_{1999\rightarrow1994}$, $\mathbf{T}_{2004\rightarrow1994}$, $\mathbf{T}^2_{2004\rightarrow1999}$, $\mathbf{T}_{2009\rightarrow1994}$, e $\mathbf{T}^3_{2009\rightarrow2004}$, foi, respectivamente, de 0,19, 0,10, 0,07, 0,05 e 0,03 pontos em comparação ao monotemporal.

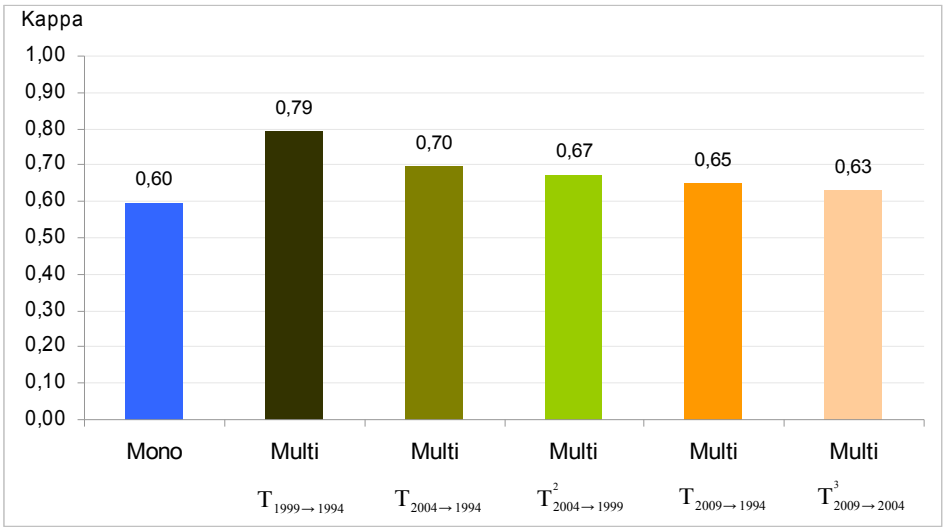

Figura 32 – Desempenho global dos classificadores em 1994

Os resultados apresentados para as classificações multitemporais em 1994 permitem chegar às seguintes conclusões:

- todas as classificações multitemporais com base nas matrizes de transição que foram estimadas diretamente apresentaram desempenho superior aos das classificações com base em matrizes de transição extrapoladas;
- o desempenho das classificações multitemporais é reduzido a medida em que se estima ou extrapola matrizes para intervalos de tempo longos; entretanto, mesmo com esta redução, as classificações multitemporais ainda apresentam resultados superiores à monotemporal.

Assim, se percebe a viabilidade do uso CMF de instâncias de tempo menores para gerar CMF combinadas com o objetivo de classificar imagens de instância de tempo maiores.

4.4 Classificação em 1989

Para 1989, foram obtidas 7 classificações multitemporais, com base em:

- $\mathbf{T}_{1994\rightarrow1989}$, estimada a partir do par de datas 1994→1989.
- $\mathbf{T}_{1999\rightarrow1989}$, estimada para a partir do par de datas 1999→1989.
- $\mathbf{T}^2_{1999\rightarrow1994}$, que representa uma matriz de transição para um intervalo de 10

anos, extrapolada a partir da matriz de transição estimada para o par de datas 1999→1994.

- $\mathbf{T}_{2004\rightarrow1989}$, estimada a partir do par de datas 2004→1989.
- $\mathbf{T}^{3}_{2004\rightarrow1999}$, que representa uma matriz de transição para um intervalo de 15 anos, extrapolada a partir da matriz de transição estimada para o par de datas 2004→1999.
- $\mathbf{T}_{2009\rightarrow1989}$, estimada a partir do par de datas 2009→1989;
- $T^{4}_{2009\rightarrow2004}$, que representa uma matriz de transição estimada para um intervalo de 20 anos, extrapolada a partir da matriz de transição estimada para o par de datas 2009→2004;

É importante ressaltar que devido a série temporal empregada, a série de 1989 foi a única que possibilitou estimar uma CMF para um intervalo de 20 anos.

Da mês forma como nos anos de 1999 e 1994, em 1989 não existe ocorrência de cobertura da classe Agropastoril, portanto, não existem resultados para esta classe.

As tabelas 16 a 23 apresentam os resultados de todas as classificações de Teste.

Tabela 16 – Resultados da classificação Monotemporal de Teste, de 1989

Matriz de Confusão					**Erros de Comissão**	**Kappa**
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**200,89**	17,27	0,96	0	8,3%	
Vegetação Secundária	30,06	**27,55**	3,80	0	55,1%	
Solo Exposto	2,36	4,07	**36,40**	0	15,0%	
Agropastoril	0	0	0	**0**	0	**0,61**
Erros de Omissão	13,9%	43,6%	11,6%	0	18,1%	
Taxa de classificação por classe	86,1%	56,4%	88,4%	0	Média 77,0%	

Tabela 17 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}_{1994\rightarrow1989}$, para 1989

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**229,48**	9,69	2,07	0	4,9%	
Vegetação Secundária	1,74	**36,61**	2,98	0	11,4%	
Solo Exposto	2,08	2,59	**36,02**	0	11,5%	
Agropastoril	0	0	0,09	**0**	100,0%	**0,85**
Erros de Omissão	1,6%	25,1%	12,5%	0	6,6%	
Taxa de classificação por classe	98,4%	74,9%	87,5%	0	Média 86,9%	

Tabela 18 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}_{1999\rightarrow1989}$, para 1989

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**231,94**	24,24	2,18	0	10,0%	
Vegetação Secundária	1,97	**22,31**	3,86	0	21,0%	
Solo Exposto	2,03	2,39	**35,22**	0	11,0%	
Agropastoril	0	0	0,06	**0**	100,0%	**0,72**
Erros de Omissão	2,0%	54,0%	15,0%	0	11,0%	
Taxa de classificação por classe	98,3%	45,6%	85,3%	0	Média 76,4%	

Tabela 19 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}^2_{1999\rightarrow1994}$, para 1989

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**231,02**	26,36	1,32	0	10,7%	**0,69**
Vegetação Secundária	1,31	**17,59**	3,01	0	19,7%	
Solo Exposto	3,32	4,73	**36,94**	0	17,9%	
Agropastoril	0,00	0,00	0,03	**0**	100,0%	
Erros de Omissão	98,0%	36,1%	89,5%	0	12,3%	
Taxa de classificação por classe	98,0%	36,1%	89,5%	0	Média 74,5%	

Tabela 20 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}_{2004\rightarrow1989}$, para 1989

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**223,99**	29,33	1,38	0	12,0%	
Vegetação Secundária	8,79	**15,79**	4,93	0	46,0%	
Solo Exposto	1,27	3,44	**35,59**	0	12,0%	
Agropastoril	0	0	0,06	**0**	100,0%	**0,63**
Erros de Omissão	4,0%	67,0%	15,0%	0	15,0%	
Taxa de classificação por classe	95,7%	32,5%	84,8%	0	Média 71,0%	

Tabela 21 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}^{3}_{2004\rightarrow1999}$, para 1989

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**227,60**	31,32	1,41	0	12,6%	
Vegetação Secundária	5,77	**13,67**	4,21	0	42,2%	
Solo Exposto	1,01	3,77	**35,49**	0	11,9%	
Agropastoril	0,00	0,00	0,01	**0**	100,0%	**0,63**
Erros de Omissão	2,9%	72,0%	13,7%	0	14,6%	
Taxa de classificação por classe	97,1%	28,0%	86,3%	0	Média 70,5%	

Tabela 22 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}_{2009\rightarrow1989}$, para 1989

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**226,53**	29,45	1,8	0	12,0%	**0,63**
Vegetação Secundária	7,38	**15,98**	4,86	0	43,0%	
Solo Exposto	1,69	3,13	**34,53**	0	12,0%	
Agropastoril	0,01	0	0,05	**0**	100,0%	
Erros de Omissão	4,0%	67,0%	16,0%	0	15,0%	
Taxa de classificação por classe	96,2%	32,9%	83,7%	0	Média 70,9%	

Tabela 23 – Resultados da classificação Multitemporal de Teste com base em $\mathbf{T}^{4}_{2009\rightarrow2004}$, para 1989

Matriz de Confusão					Erros de Comissão	Kappa
Classes	Vegetação Primária	Vegetação Secundária	Solo Exposto	Agropastoril		
Vegetação Primária	**232,61**	32,79	3,63	0	13,5%	
Vegetação Secundária	2,59	**12,61**	3,73	0	33,4%	
Solo Exposto	0,38	3,10	**34,17**	0	9,2%	
Agropastoril	0,00	0,00	0,01	**0**	100,0%	**0,62**
Erros de Omissão	1,3%	74,0%	17,7%	0	14,2%	
Taxa de classificação por classe	98,7%	26,0%	82,3%	0	Média 69,0%	

Com o objetivo de iniciar uma análise detalhada dos resultados apresentados nas tabelas anteriores, a Figura 33 apresenta as taxas de classificação por classe das classificações monotemporal e multitemporais.

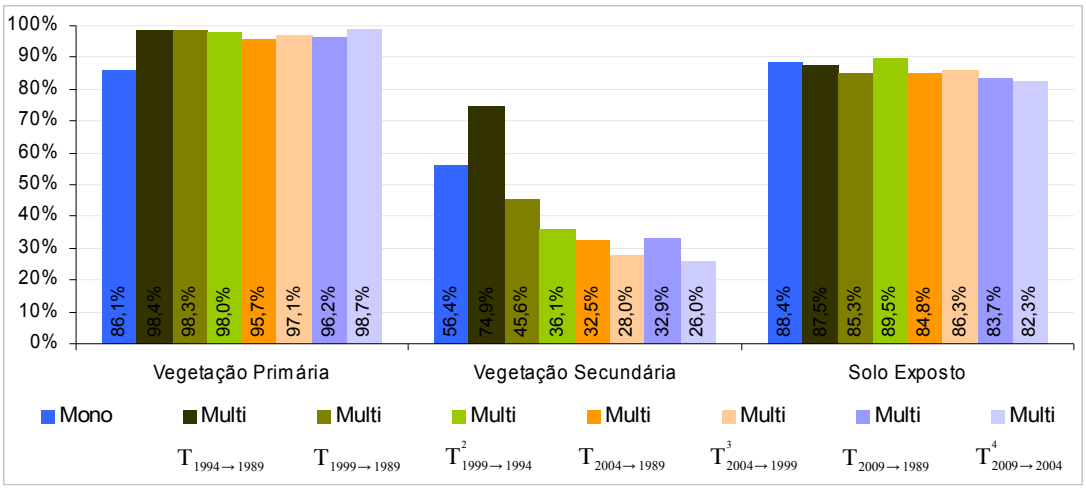

Figura 33 – Desempenho das classificações por classe em 1989

Pelos resultados das classificações por classe, verifica-se que ambas classificações multitemporais apresentaram resultados superiores à monotemporal para a classe Vegetação Primária, sendo que o ganho mais expressivo foi de 12,6% ($\mathbf{T}^{4}_{2009\rightarrow2004}$) e o menos expressivo foi de 9,6% ($\mathbf{T}_{2004\rightarrow1999}$), resultado que representa uma melhora significativa na classificação.

Para classe Vegetação Secundária ocorre a mesma relação observada nas análises dos anos anteriores, onde a única classificação multitemporal que apresentou ganho foi com base em $\mathbf{T}_{1994\rightarrow1989}$, e as demais apresentaram queda que chegou a 30,4% ($\mathbf{T}^{4}_{2009\rightarrow2004}$).

Para a classe Solo Exposto, apesar de os resultados das classificações multitemporais apresentarem valores próximos aos da monotemporal, a única classificação multitemporal com desempenho superior a monotemporal foi a com base em $\mathbf{T}^2_{1999\rightarrow1994}$, com ganho de 1,1%.

A Figura 34 apresenta os resultados classe a classe das diversas classificações para os conjuntos de treinamento e de teste. A partir destes resultados, é possível identificar que as classificações multitemporais com base em matrizes de transição estimadas diretamente ($\mathbf{T}_{1994\rightarrow1989}$,$\mathbf{T}_{1999\rightarrow1989}$, $\mathbf{T}_{2004\rightarrow1989}$ e $\mathbf{T}_{2009\rightarrow1989}$) apresentaram pequena queda no desempenho da classificação de Teste em relação ao Treinamento para as classes Vegetação Secundária e Solo Exposto. Além disso, mas estes resultados apresentaram desempenho superior aos das classificações com base nas com base matrizes de transição extrapoladas ($\mathbf{T}^2_{1999\rightarrow1994}$, $\mathbf{T}^3_{2004\rightarrow1999}$ e $\mathbf{T}^4_{2009\rightarrow2004}$,), onde os valores de Treinamento e Teste são muito próximos.

Verifica-se, ainda, que a classificação com base em $\mathbf{T}_{1994\rightarrow1989}$ foi a mais estável, pois apresentou maior desempenho na etapa de Treinamento não apenas para as classes Vegetação Primária e Solo Exposto, como também para Vegetação Secundária. Na classificação de Teste, para a classe Solo Exposto, apresentou uma pequena queda e não atingiu os resultados em torno dos 90% do Treinamento; contudo, esta queda foi pouco significativa.

Semelhante a análise dos anos anteriores, as classificações multitemporais apresentaram queda significativa na classe Vegetação Secundária, tanto na etapa de treinamento quanto de Teste, indicando um problema de confusão para este classe.

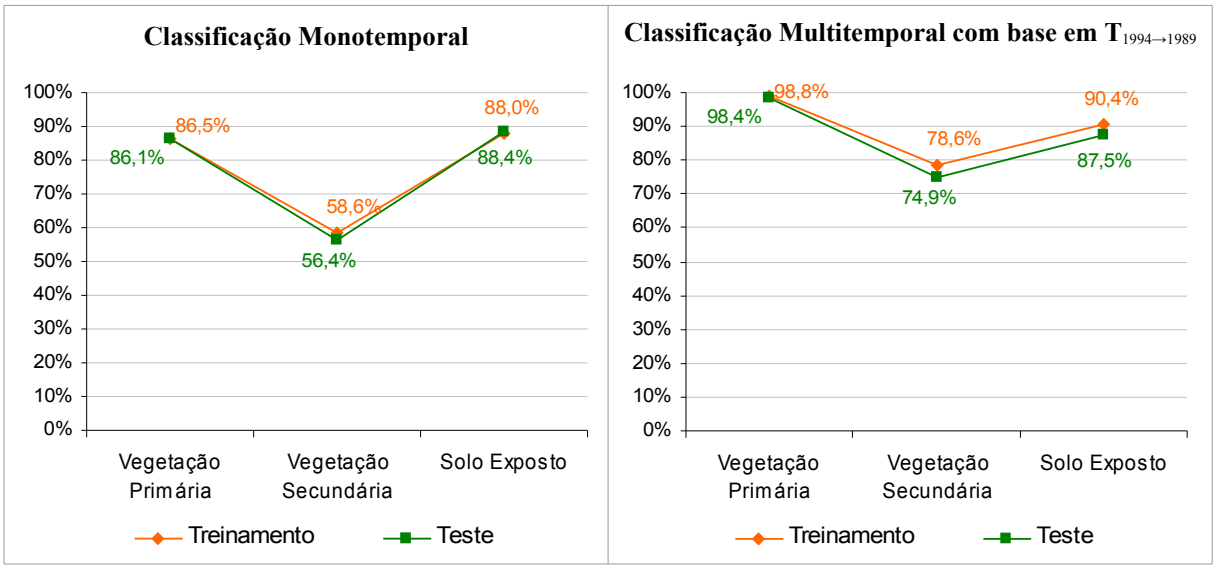

Figura 34 – Taxas de classificação para Treinamento e Teste em 1989. (continua)

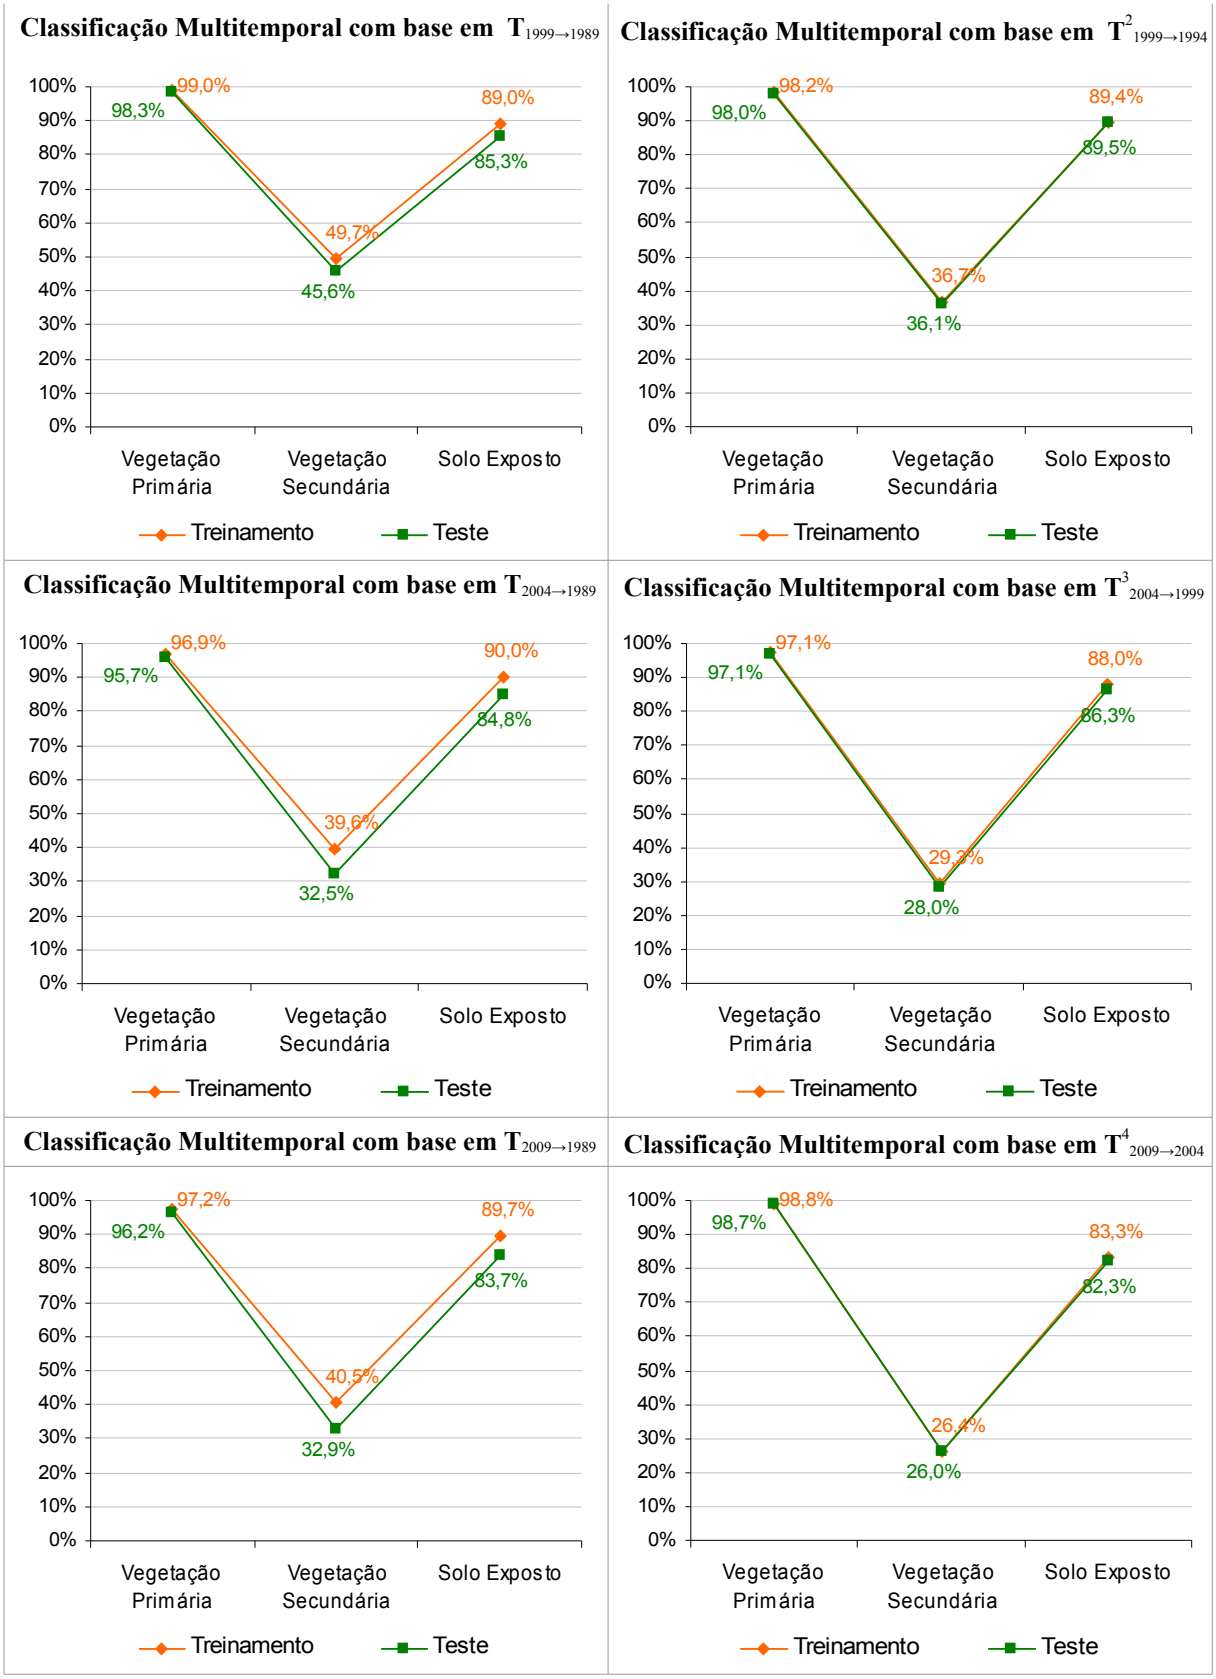

Figura 34 – Taxas de classificação para Treinamento e Teste em 1989. (conclusão)

A Figura 35 apresenta os Erros de Comissão e Omissão para as classificações.

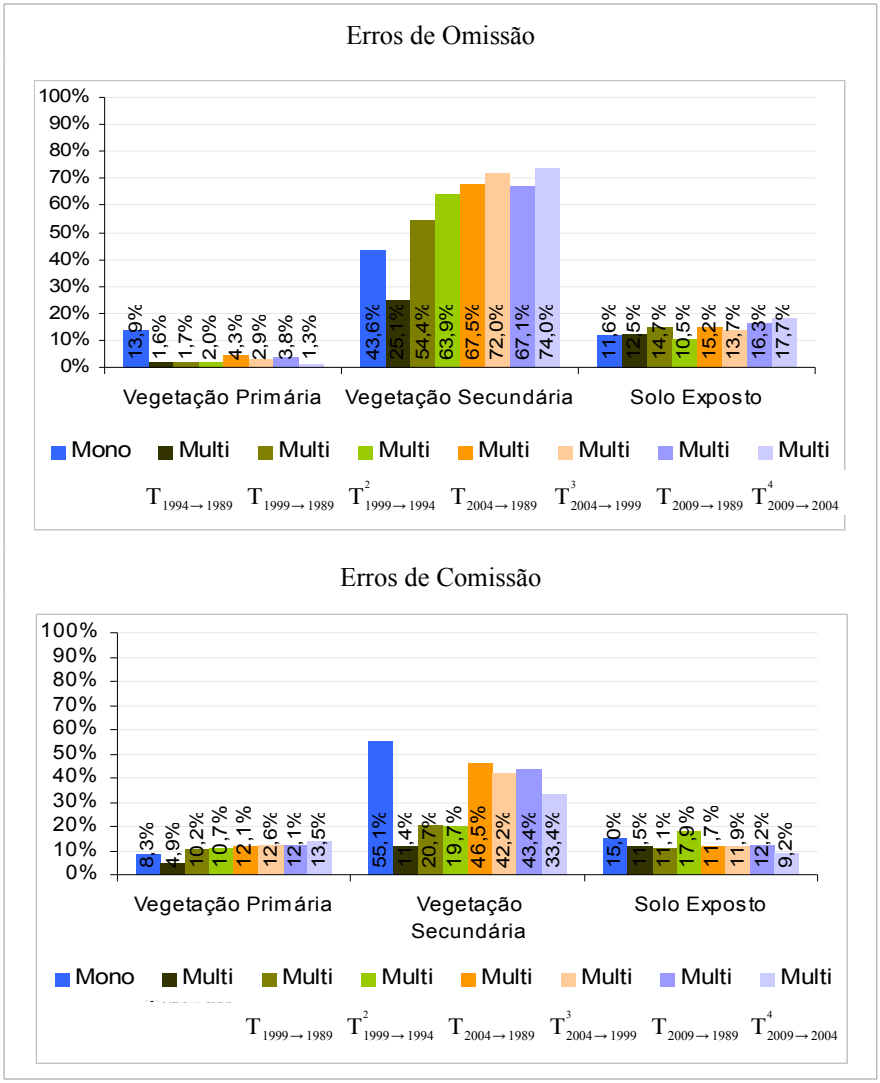

Figura 35 – Erros de Omissão e Comissão das classificações de Teste em 1989.

De modo geral, percebe-se que a classificação que apresentou menores erros, tanto EO quanto EC, foi a com base em $\mathbf{T}_{1994\rightarrow1989}$. Também, é possível observar que os EO para a classe Vegetação Secundária são altos para as demais classificações multitemporais e, em contrapartida, os EC apresentam desempenhos significativos em relação à monotemporal.

Para a classe Vegetação Primária ocorre o inverso da Vegetação Secundária, os EO das classificações multitemporais são melhores em comparação com à monotemporal, mas os EC apresentam pequeno aumento.

Para a classe Solo Exposto visualiza-se que tanto os EO quanto os EC das classificações multitemporais apresentam valores próximos da monotemporal. Tomando como

base as matrizes de confusão, é possível identificar que isso ocorre porque houve muita confusão da classe Solo Exposto com a classe Vegetação Secundária e, em alguns casos, com a classe Vegetação Primária.

Finalizando a análise de 1989, é possível visualizar o resultado global das classificações através do índice Kappa, apresentado na Figura 36.

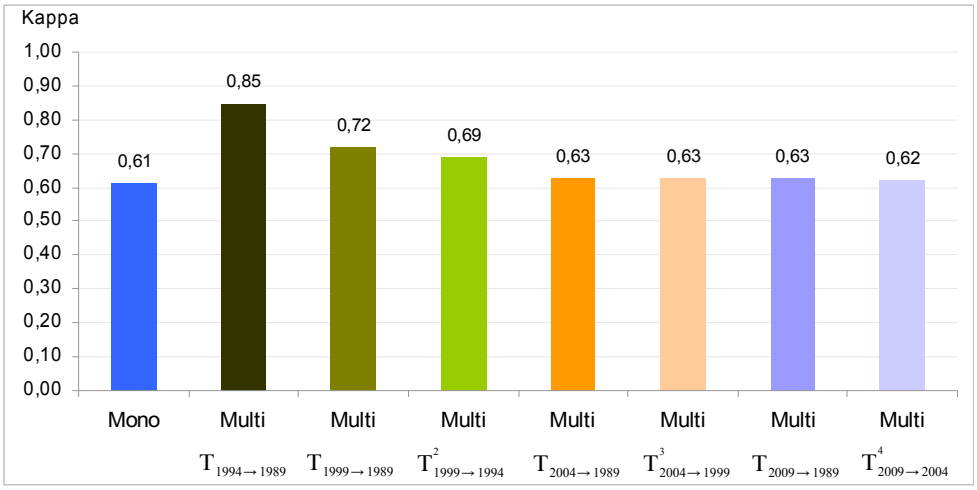

Figura 36 – Desempenho global das classificações em 1989

Pelos desempenhos apresentados com o uso do índice Kappa é possível verificar que todas as classificações multitemporais foram superiores a monotemporal; entretanto, os resultados das classificações multitemporais para períodos de 15 e 20 anos foram próximos ao monotemporal.

Assim como ocorrido para o ano de 1999, é possível observar que as matrizes de transição estimadas diretamente sempre apresentaram resultados superiores aos das classificações com base nas matrizes de transição extrapoladas. Também, que o desempenho das classificações multitemporais diminui a medida em que se estima ou extrapola matrizes para intervalos de tempo cada vez mais longos.

Pela análise realizada, conclui-se que, apesar dos problemas apresentados com a confusão de algumas coberturas de uso da terra, os classificadores multitemporais possibilitaram a melhora da classificação mesmo utilizado CMF combinadas para classificar instâncias de tempo maiores, de 10, 15 e 20 anos.

4.5 Síntese das Classificações Multitemporais

O objetivo desta seção é sintetizar as análises realizadas nas seções anteriores a fim de se ter uma visão geral das classificações e dos desempenhos apresentados.

A Tabela 24 e aFigura 37 apresentam o desempenho global (índice Kappa) das classificações de Teste para toda a série analisada, de 2004 a 1989.

Tabela 24 – Resultados do desempenho global das classificações de Teste, de 2004 a 1989

Classificação	Índice Kappa				Média do Kappa para toda série	Ganho médio em relação classificação Monotemporal
	2004	1999	1994	1989		
Monotemporal	0,60	0,57	0,60	0,61	0,60	-
Multitemporal $\mathbf{T}_{k\rightarrow k+1}$	0,82	0,79	0,79	0,85	0,81	0,22
Multitemporal $\mathbf{T}_{k\rightarrow k+2}$	-	0,70	0,70	0,72	0,71	0,11
Multitemporal $\mathbf{T}^{2}_{k\rightarrow k+1}$	-	0,65	0,67	0,69	0,67	0,08
Multitemporal $\mathbf{T}_{k\rightarrow k+3}$	-	-	0,65	0,63	0,64	0,05
Multitemporal $\mathbf{T}^{3}_{k\rightarrow k+1}$	-	-	0,63	0,63	0,63	0,04
Multitemporal $\mathbf{T}_{k\rightarrow k+4}$	-	-	-	0,63	0,63	0,04
Multitemporal $\mathbf{T}^{4}_{k\rightarrow k+1}$	-	-	-	0,62	0,62	0,03

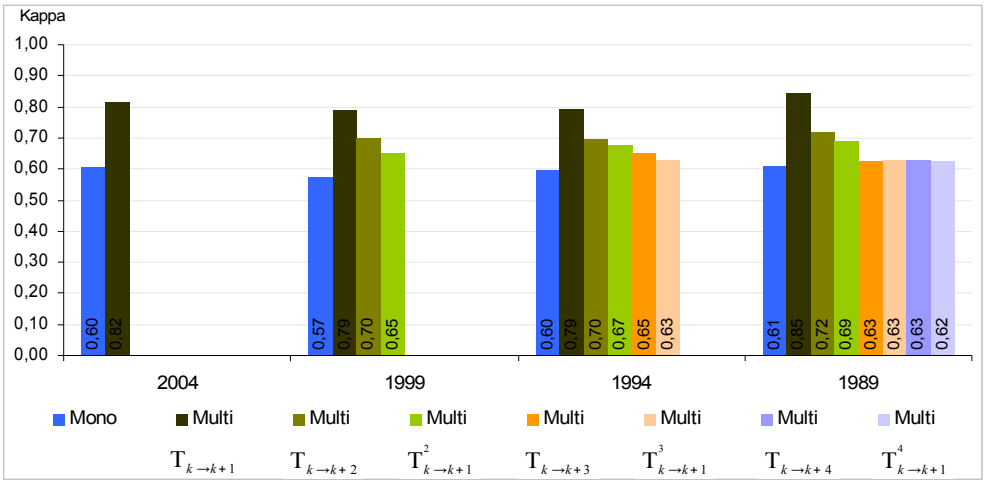

Figura 37 – Desempenho global dos classificadores

Inicialmente, pode-se verificar que todas as classificações multitemporais apresentaram resultados superiores às monotemporais. Pode-se verificar, também, que tanto

as classificações monotemporais quandto as multitemporais apresentaram estabilidade em relação a variação dos índices Kappa para toda a série analisada. Por exemplo, para as classificações monotemporais o menor desempenho foi de 0,57 (1999) e o maior de 0,61 (1989), o que representa uma variação máxima de 0,04 pontos. Já para as classificações multitemporais com base em $\mathbf{T}_{k\rightarrow k+1}$ o menor desempenho foi de 0,79 (1999 e 1994) e o maior de 0,85, indicando uma variação de 0,06 pontos. Para as demais classificações multitemporais com base em $\mathbf{T}_{k\rightarrow k+2}$, $\mathbf{T}^2_{k\rightarrow k+1}$, $\mathbf{T}_{k\rightarrow k+3}$ e $\mathbf{T}^3_{k\rightarrow k+1}$, as variações foram, respectivamente, de 0,02, 0,04, 0,02 e 0,00 pontos.

A Figura 38 apresenta os resultados do ganho médio das classificações multitemporais em relação às monotemporais. Estes resultados são importantes porque traduzem a expectativa relacionada aos classificadores multitemporais estimados diretamente e extrapoladas.

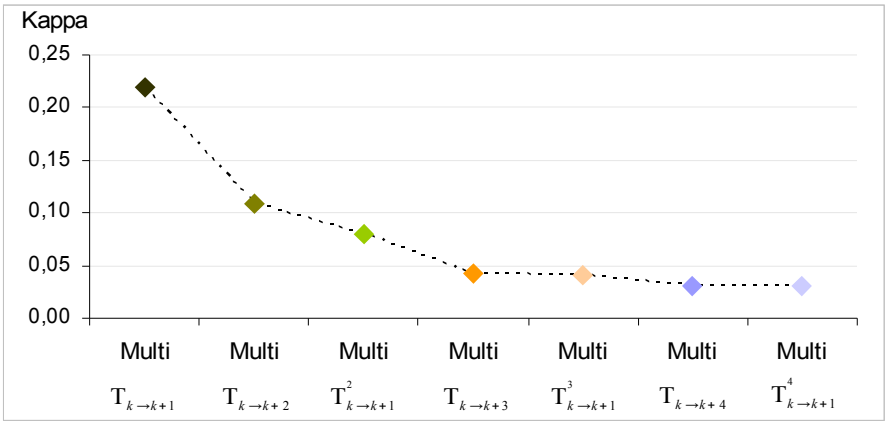

Figura 38 – Ganho médio das classificações multitemporais em relação às monotemporais

Pode-se constatar que as classificações multitemporais com base nas matrizes de transição extrapoladas para classificar instâncias de tempo maiores, $\mathbf{T}^2_{k\rightarrow k+1}$ (10 anos), $\mathbf{T}^3_{k\rightarrow k+1}$ (15 anos) e $\mathbf{T}^4_{k\rightarrow k+1}$ (20 anos), apresentam queda gradativa nos resultados das classificações em comparação com as classificações com base nas matrizes de transição estimadas diretamente, $\mathbf{T}_{k\rightarrow k+2}$ (10 anos), $\mathbf{T}_{k\rightarrow k+3}$ (15 anos) e $\mathbf{T}_{k\rightarrow k+4}$ (20 anos). Isso evidencia a tendência de que, quanto maior a extrapolação de uma matriz de transição do conhecimento temporal, com o objetivo de classificar uma imagem de instância de tempo maior, menor será o ganho apresentado na classificação.

Na Tabela 25 e na Figura 39 é possível verificar os Erros Totais das classificações de

Teste para toda a série analisada.

Tabela 25 – Resultados das Erros Totais das classificações de Teste, de 2004 a 1989

Classificação	% de Erro				Média do Erros para toda série %	Redução média do erro em relação a classificação Monotemporal - %
	2004	1999	1994	1989		
Monotemporal	14,1	14,9	19,1	18,1	16,6	-
Multitemporal $\mathbf{T}_{k\to k+1}$	5,6	7,2	8,1	6,6	6,9	9,7
Multitemporal $\mathbf{T}_{k\to k+2}$	-	9,9	11,9	11,3	11,0	5,5
Multitemporal $\mathbf{T}^2_{k\to k+1}$	-	11,0	12,6	12,3	12,0	4,6
Multitemporal $\mathbf{T}_{k\to k+3}$	-	-	13,6	15,2	14,4	2,2
Multitemporal $\mathbf{T}^3_{k\to k+1}$	-	-	13,7	14,6	14,2	2,4
Multitemporal $\mathbf{T}_{k\to k+4}$	-	-	-	14,9	14,9	1,7
Multitemporal $\mathbf{T}^4_{k\to k+1}$	-	-	-	14,2	14,2	2,4

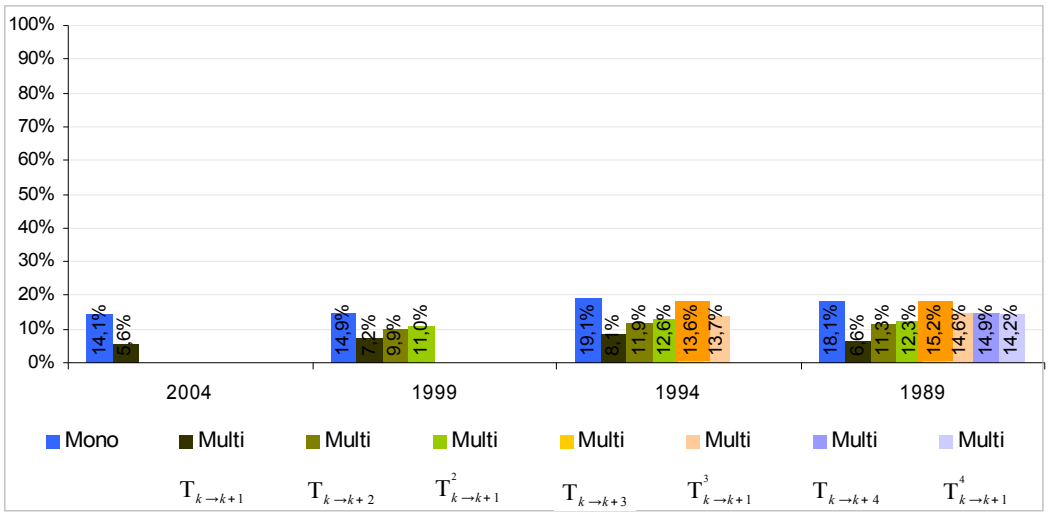

Figura 39 – Erros totais das classificações monotemporais e multitemporais

Os erros totais apresentados correspondem a maior ou menor confusão entre as classes apresentadas nas matrizes de confusão.

Pode-se perceber a classificação com base em $\mathbf{T}_{k\to k+1}$ apresentou melhor desempenho na redução dos erros, em comparação com a monotemporal. Ainda, apesar dos erros das classificações multitemporais para intervalos de 15 e 20 anos serem próximos aos erros das classificações monotemporais, existiu uma redução deste erro nas classificações multitemporais.

É importante ressaltar que, no método analisado, quanto mais semelhante for a relação dinâmica entre duas ou mais instâncias de tempo, melhor será o resultado da classificação

multitemporal. Em geral, instâncias de tempo de intervalos temporais mais longos tendem a uma redução da semelhança da dinâmica, piorando o resultado da classificação.

Entretanto, pode-se dizer que o melhor desempenho apresentado pelos classificadores multitemporais mostra a eficiência do uso classificadores que fazem uso das Cadeias de Markov Fuzzy para a molagem do conhecimento temporal, fazendo com que esta metodologia possa ser utilizada em diversos outros trabalhos de mapeamento de uso e cobertura da terra. Ainda, verifica-se que é possível obter bons resultados na classificação de imagens de instância de tempo mais distantes por meio da combinação de CMF de tempos curtos.

4.6 Espacialização das taxas de acerto das classificações multitemporais

O objetivo desta seção é realizar uma breve análise espacial das classificações multitemporais. Basicamente, pretende-se verificar, espacialmente, quais as regiões que apresentaram maiores taxas de acerto e de erro.

4.6.1 Espacialização das taxas de acerto para as classificações do ano de 2004

Na Figura 40 percebe-se que, para classificação multitemporal com base em $\mathbf{T}_{2009\rightarrow2004}$, houve de 90% a 100% de acerto na classificação para a maior parte da área de estudo, sendo que os poucos segmentos que apresentaram maiores erros estão relacionados as classes Solo Exposto e Agropastoril.

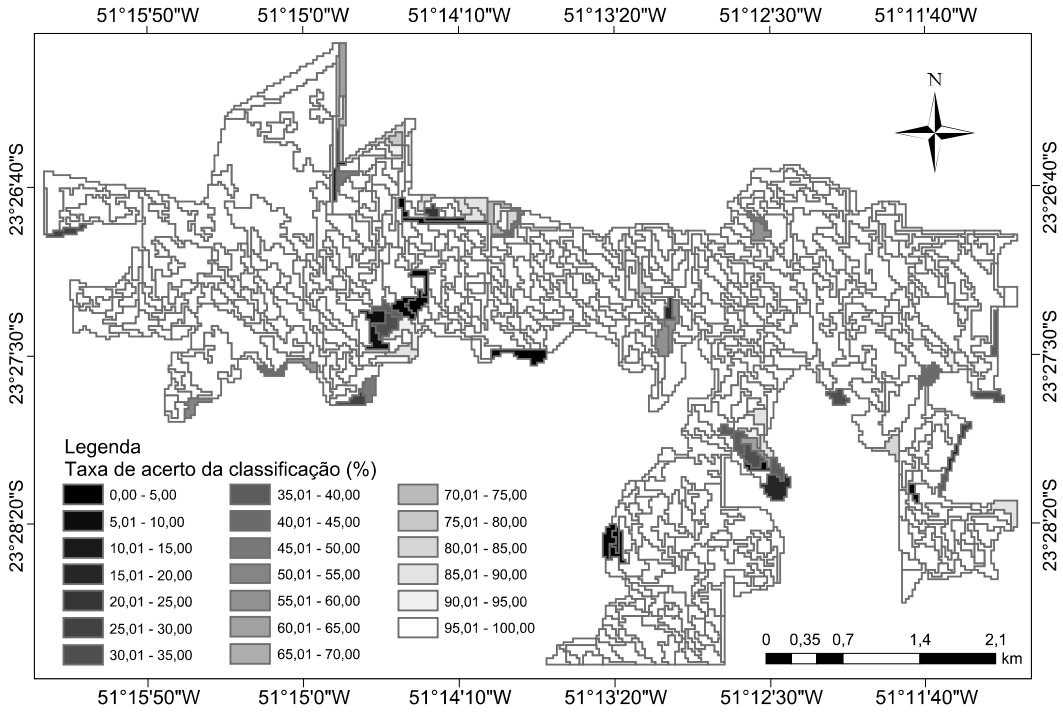

Figura 40 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{2009\rightarrow2004}$

4.6.2 Espacialização das taxas de acerto para as classificações do ano de 1999

A Figura 41 mostra a espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{2004\rightarrow1999}$, onde é possível perceber que as áreas com maiores erros estão localizadas principalmente ao centro-sul da área de estudo, e se refere a uma região onde existe a mudança significativa da classe Solo Exposto para Vegetação Secundária no período em análise.

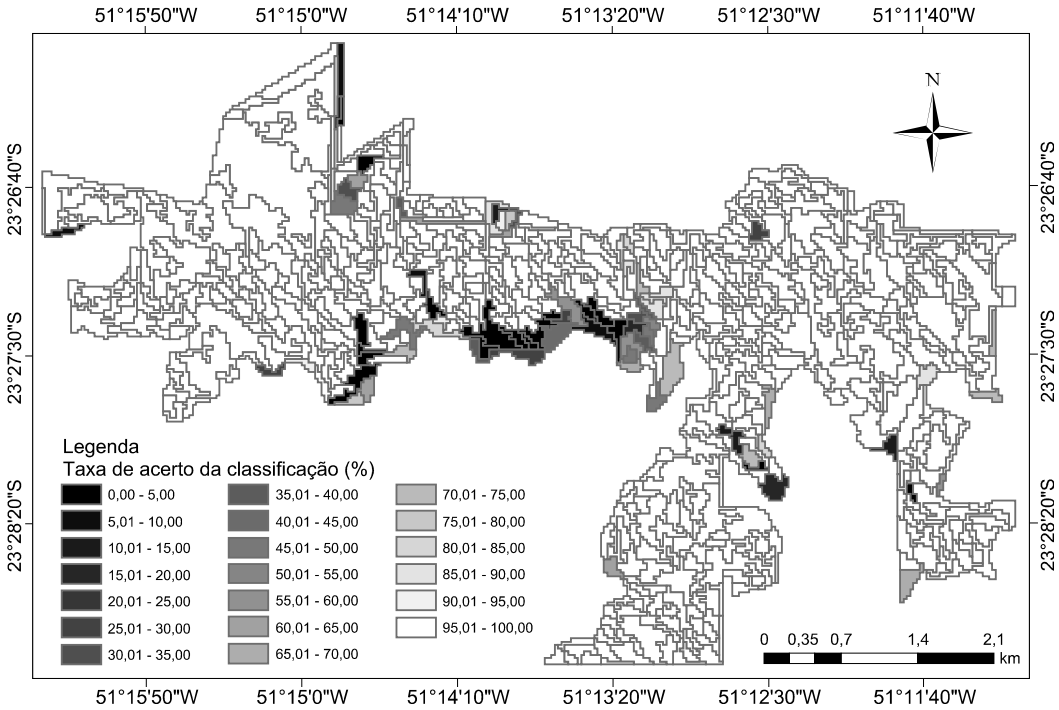

Figura 41 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{2004\rightarrow1999}$

As figuras 42 e 43 apresentam a espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{2009\rightarrow1999}$ e $\mathbf{T}^2_{2009\rightarrow2004}$. Pode-se verificar que as áreas onde ocorrem as piores taxas de classificação são as mesmas da classificação com base em $\mathbf{T}_{2004\rightarrow1999}$. Observa-se ainda o acréscimo do erro em segmentos próximos aos que apresentaram erro significativo com o uso de $\mathbf{T}_{2004\rightarrow1999}$.

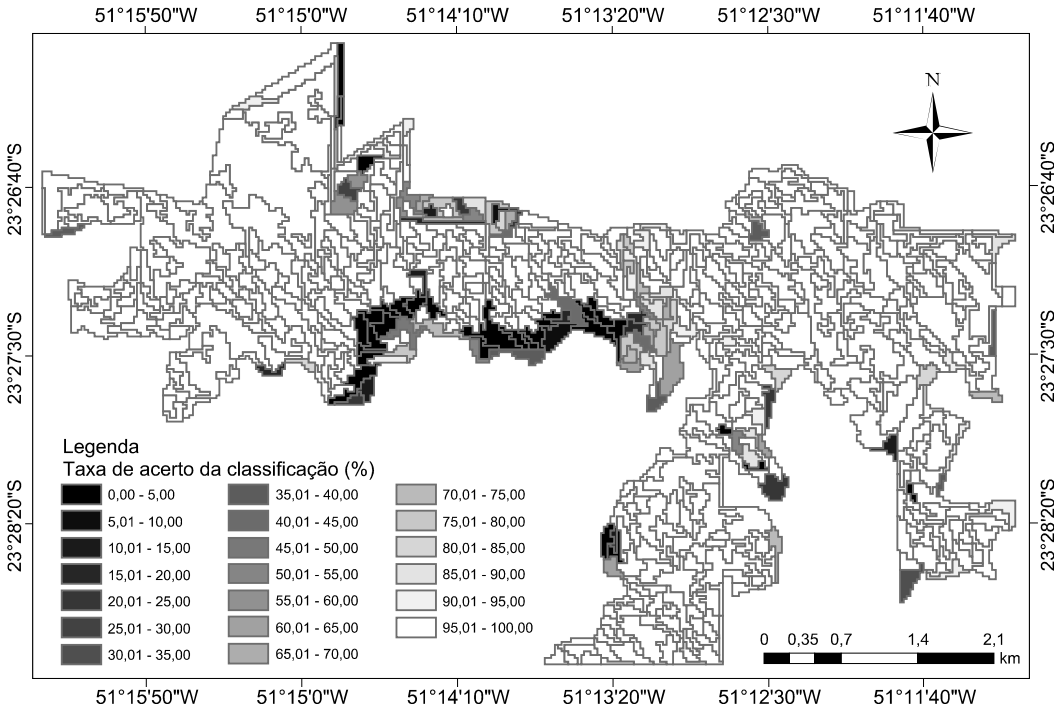

Figura 42 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{2009\rightarrow1999}$

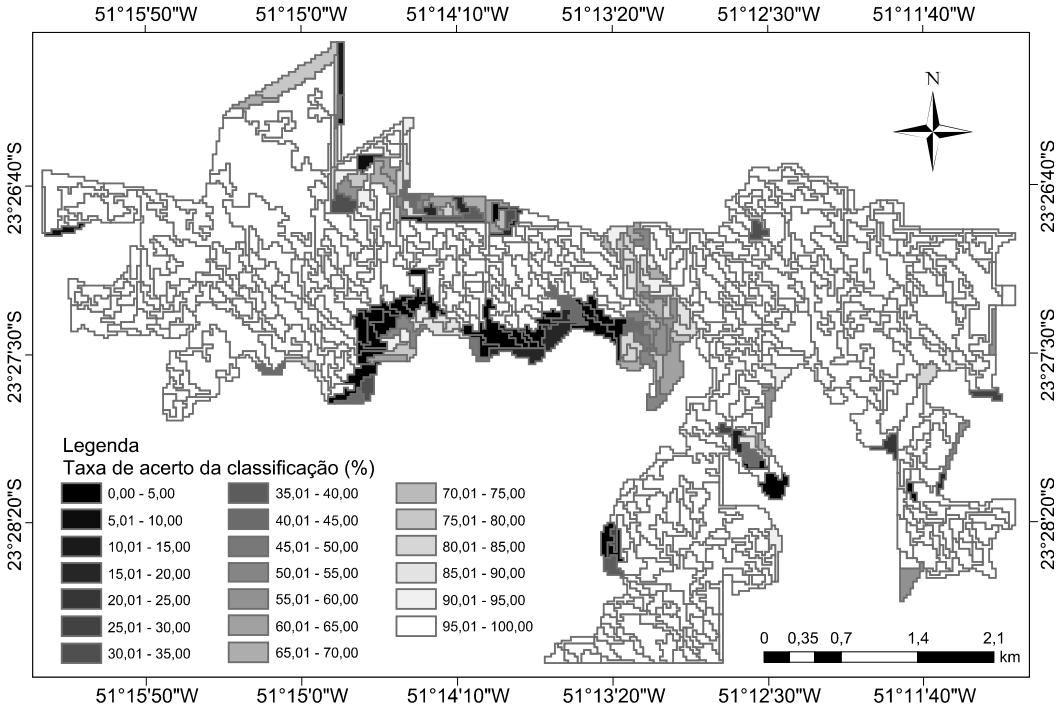

Figura 43 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}^2_{2009\rightarrow2004}$

4.6.3 Espacialização das taxas de acerto para as classificações do ano de 1994

As figuras 44 a 48 apresentam a espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{1999\rightarrow1994}$, $\mathbf{T}_{2004\rightarrow1994}$, $\mathbf{T}^2_{2004\rightarrow1999}$, $\mathbf{T}_{2009\rightarrow1994}$ e $\mathbf{T}^3_{2009\rightarrow2004}$.

Verifica-se que as áreas com maiores erros estão localizadas principalmente ao centro-sul e alguns segmentos ao leste da área de estudo. Deve-se mencionar, que a região centro sul é a que sofreu maior dinâmica no período em análise, caracterizada pela mudança de segmentos entre as classes Solo Exposto e Vegetação Secundária. Pode-se observar também que o acréscimo no número de segmentos com baixa taxa de acerto, relacionada ao aumento da distância temporal, ocorre nestas mesmas regiões geográficas, mas sempre relacionado à mesma região geográfica.

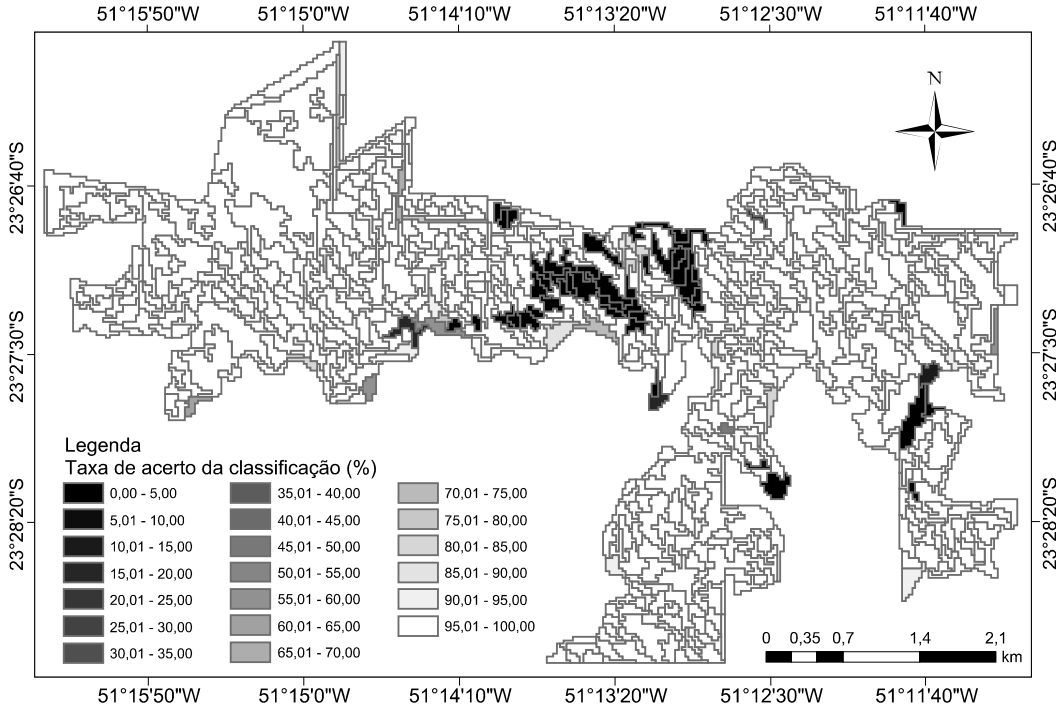

Figura 44 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{1999\rightarrow1994}$

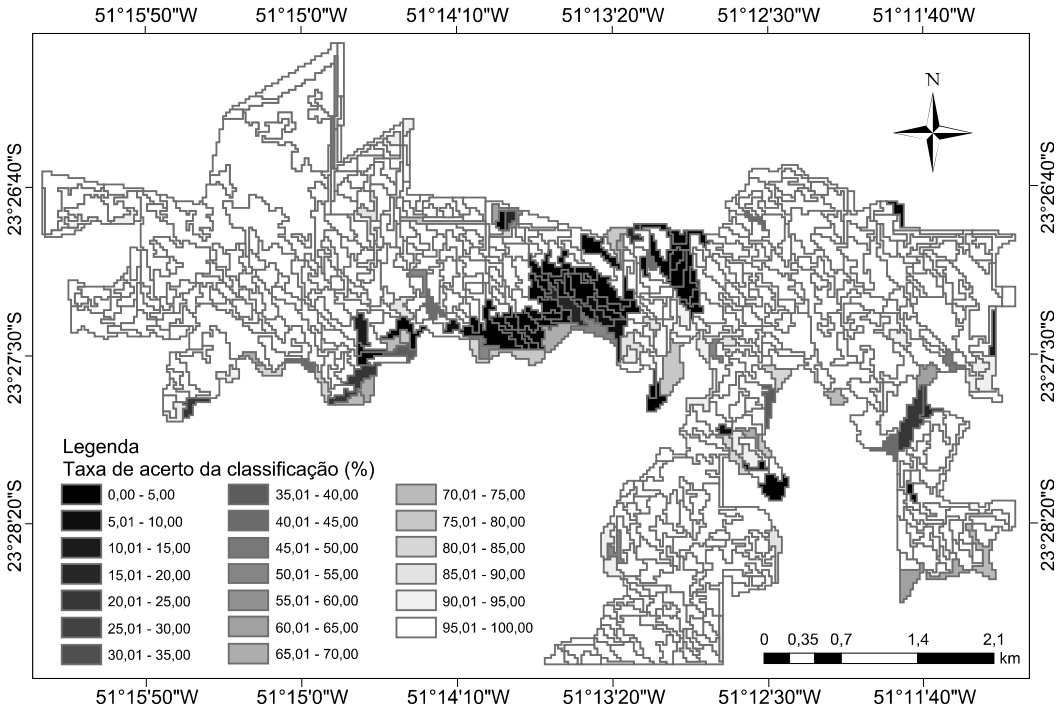

Figura 45 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{2004\rightarrow1994}$

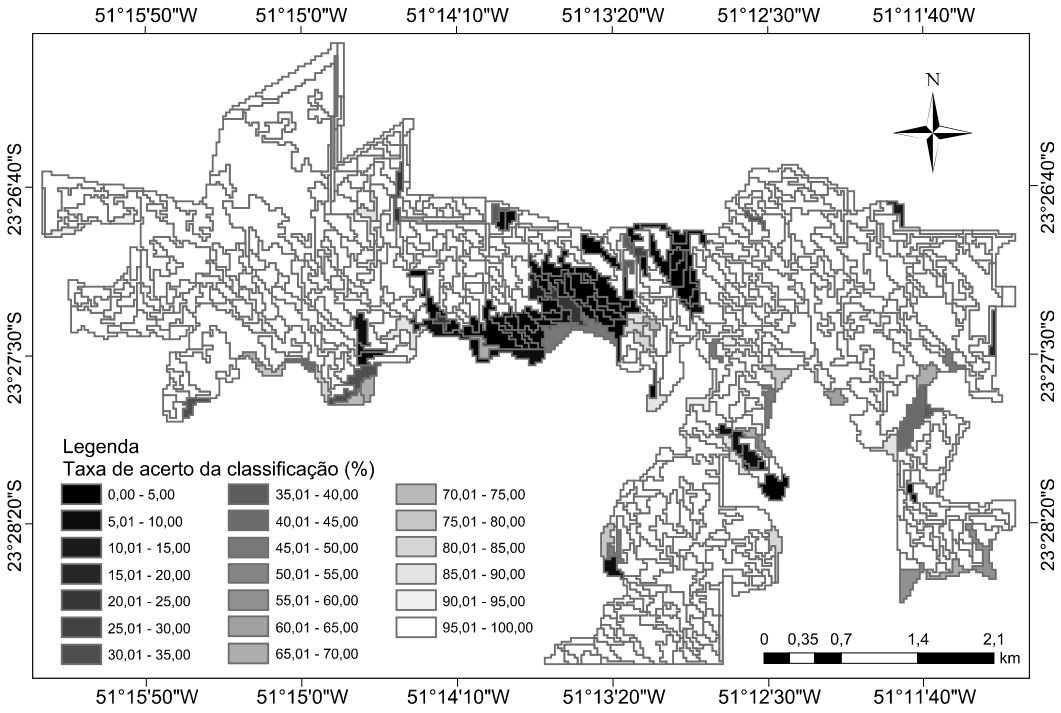

Figura 46 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}^2_{2004\rightarrow1999}$

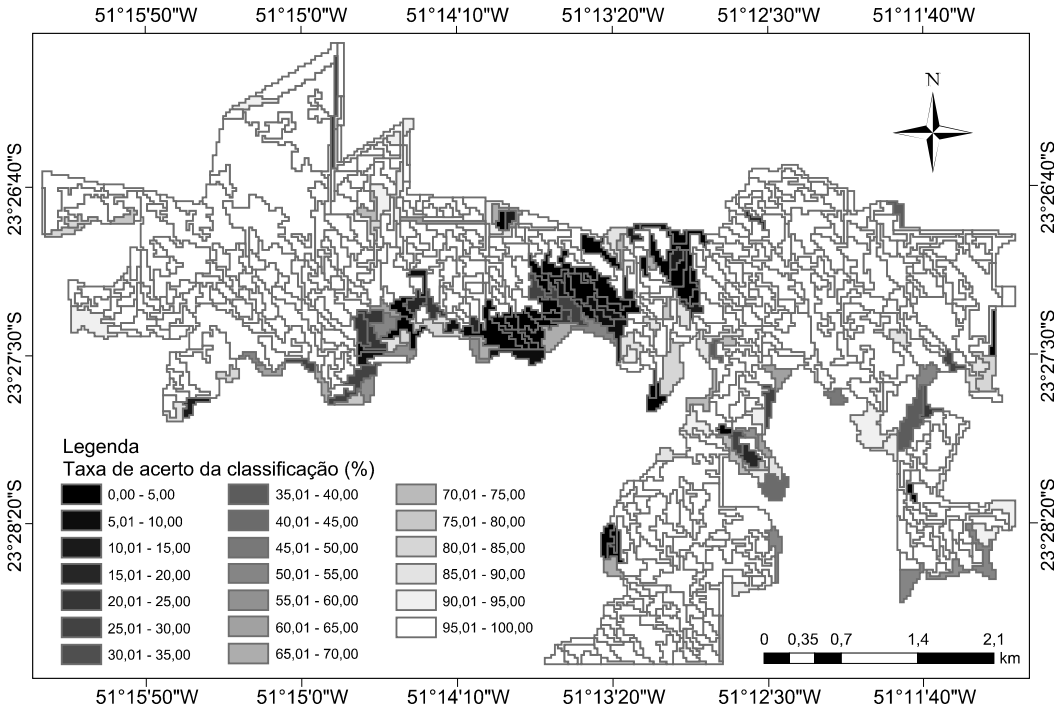

Figura 47 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{2009\rightarrow1994}$

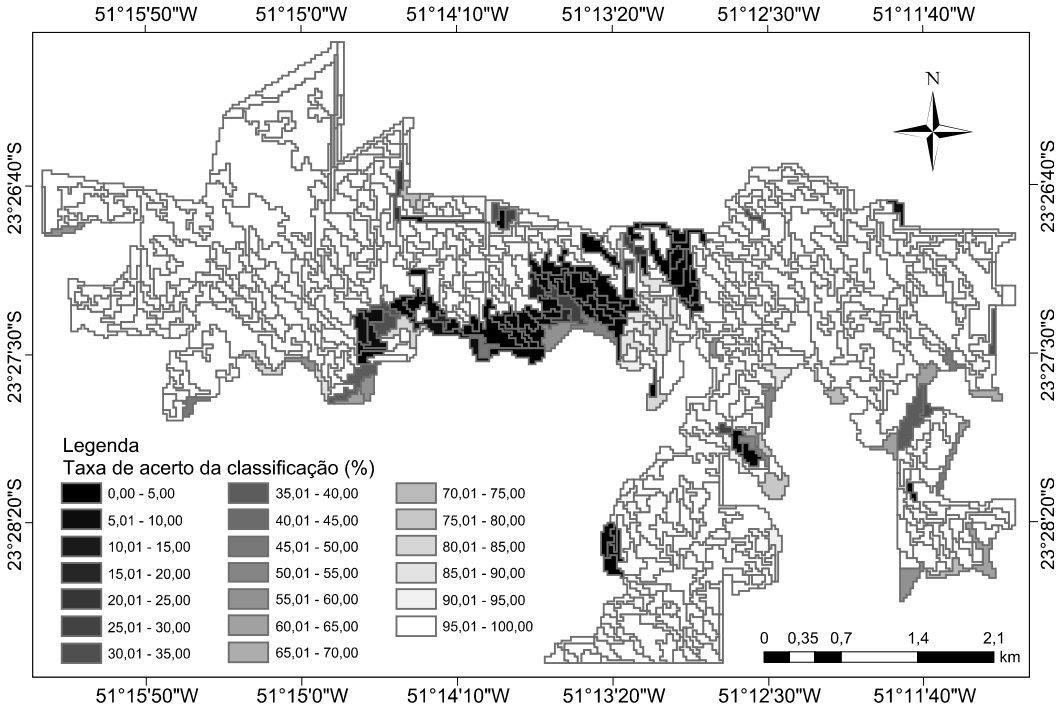

Figura 48 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}^{3}_{2009\rightarrow2004}$

4.6.4 Espacialização das taxas de acerto para as classificações do ano de 1989

As figuras 49 a 55 apresentam a espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{1994\rightarrow1989}$, $\mathbf{T}_{1999\rightarrow1989}$, $\mathbf{T}^{2}_{1999\rightarrow1994}$, $\mathbf{T}_{2004\rightarrow1989}$, $\mathbf{T}^{3}_{2009\rightarrow1994}$, $\mathbf{T}_{2009\rightarrow1989}$ e $\mathbf{T}^{4}_{2009\rightarrow2004}$.

Ao contrário dos anos anteriores, verifica-se uma diferença significativa para a classificação com base em $\mathbf{T}_{1994\rightarrow1989}$, onde as áreas com maiores erros estão localizadas principalmente ao centro-norte e alguns segmentos espalhados por toda a região, em relação as outras classificações multitemporais para 1989.

Para as demais classificações, os principais erros ocorrem em toda a região central da área de estudo. É importante verificar que é nesta região onde ocorreu a maior dinâmica temporal relacionada à mudança da classe Solo Exposto para Vegetação Secundária e, posteriormente, para Vegetação Primária.

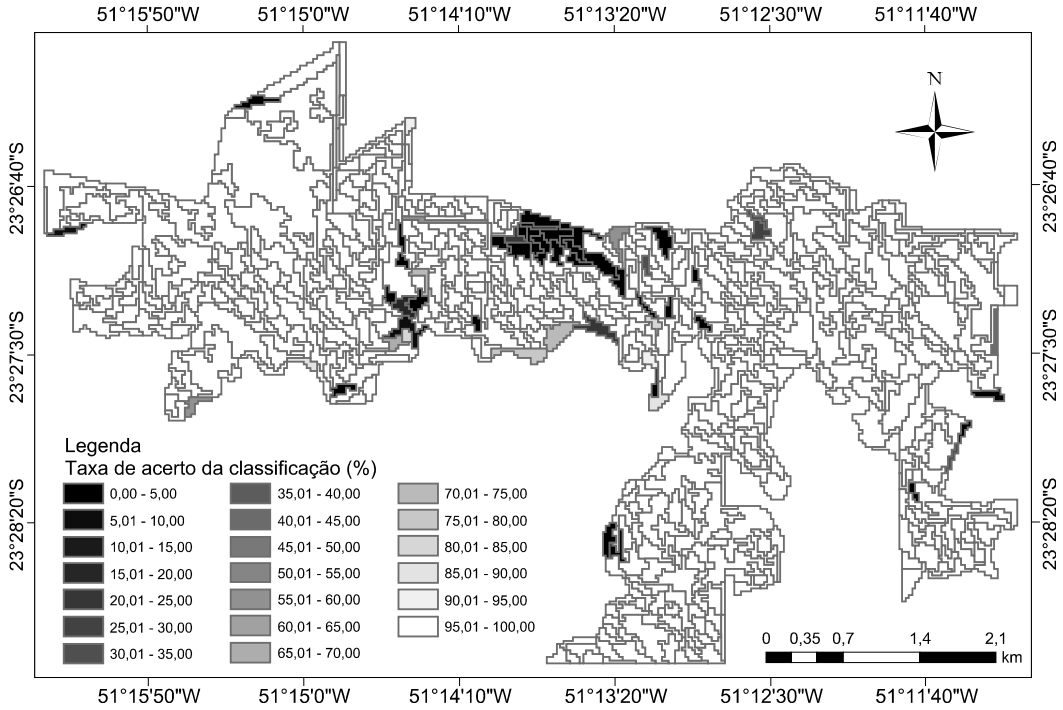

Figura 49 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{1994\rightarrow1989}$

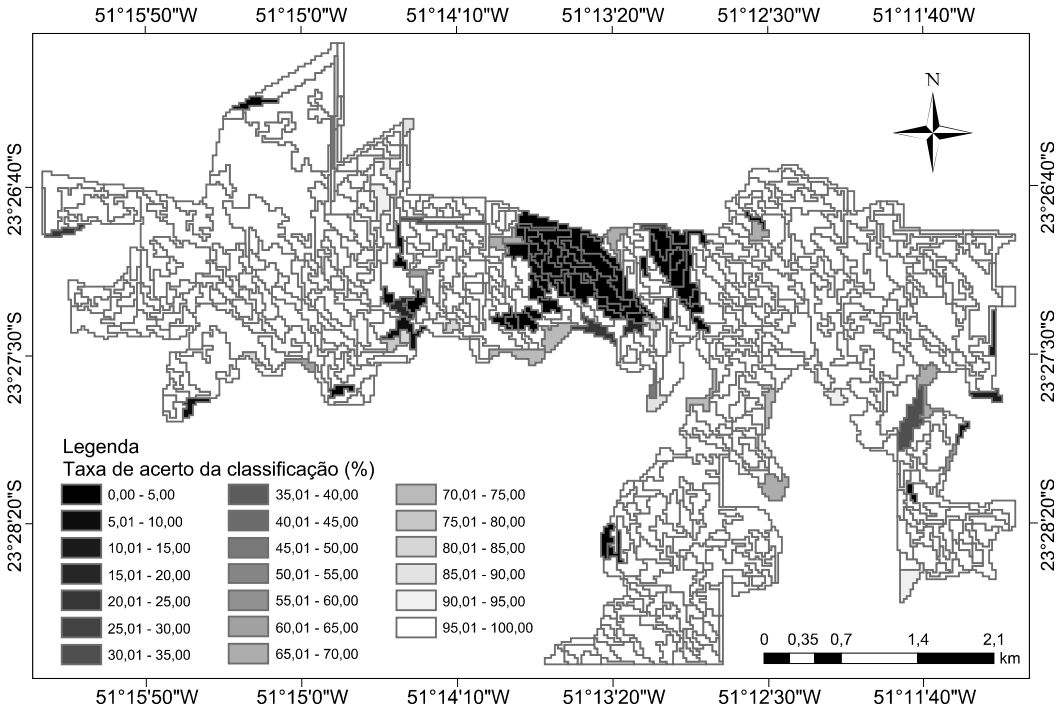

Figura 50 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{1999\rightarrow1989}$

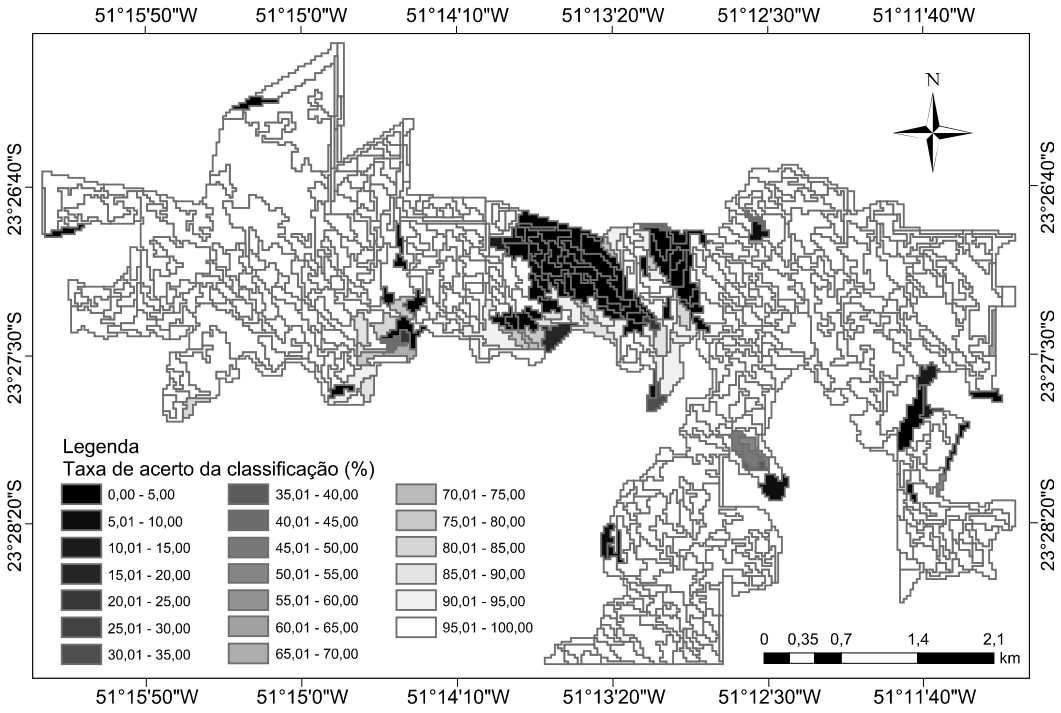

Figura 51 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}^2_{1999\rightarrow1994}$

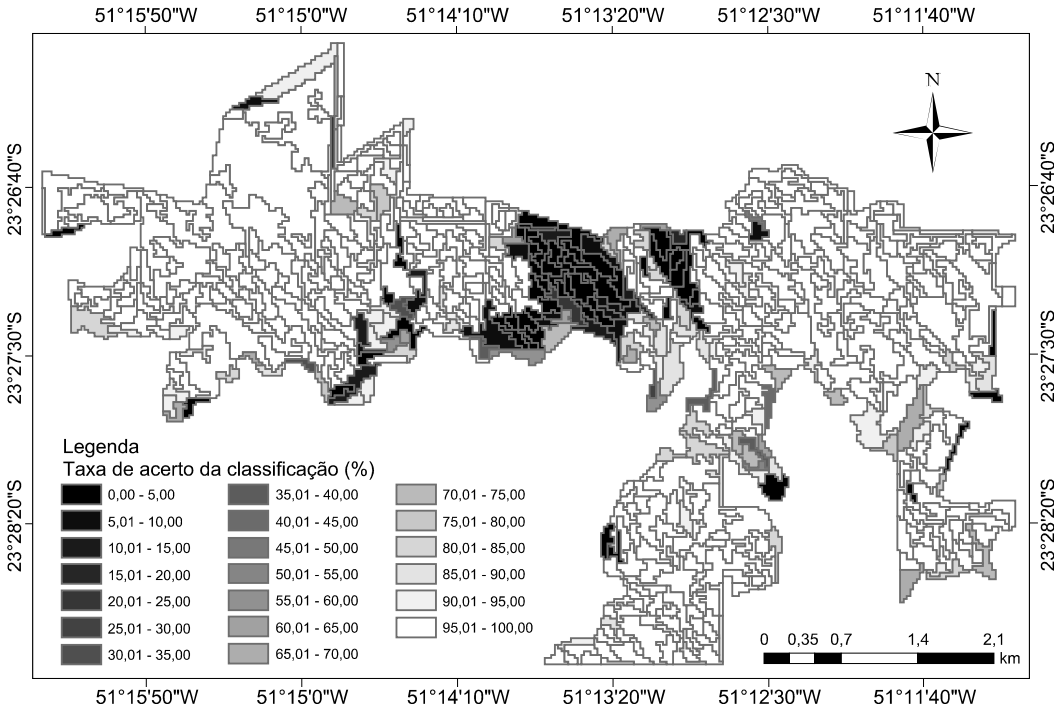

Figura 52 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{2004\rightarrow1989}$

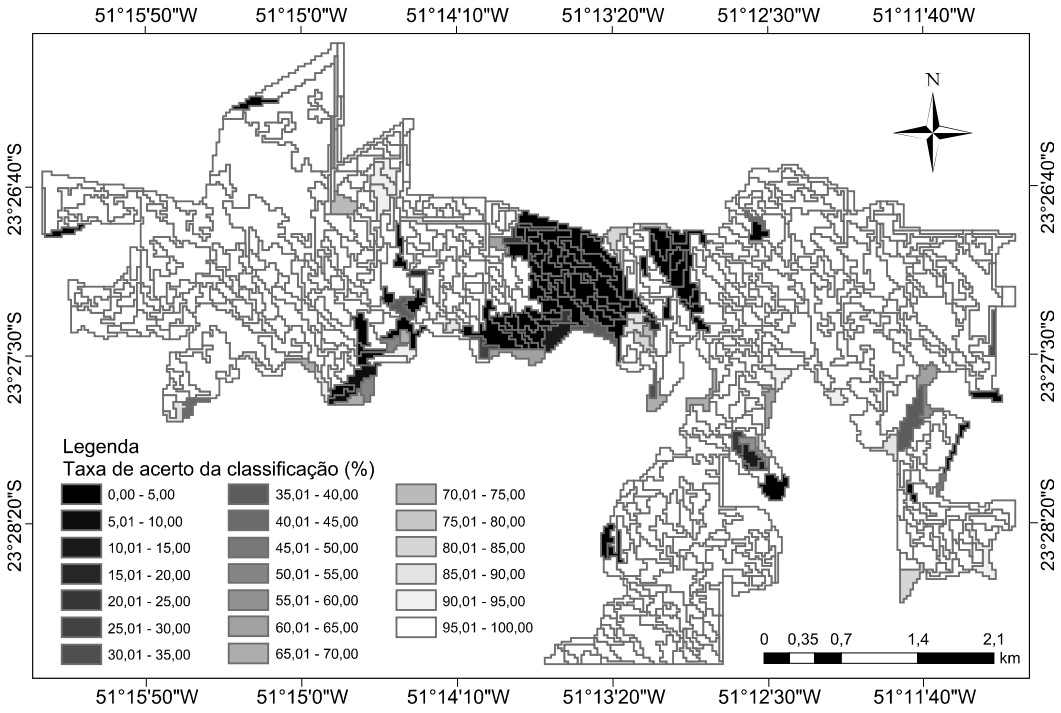

Figura 53 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}^{3}_{2004\rightarrow1999}$

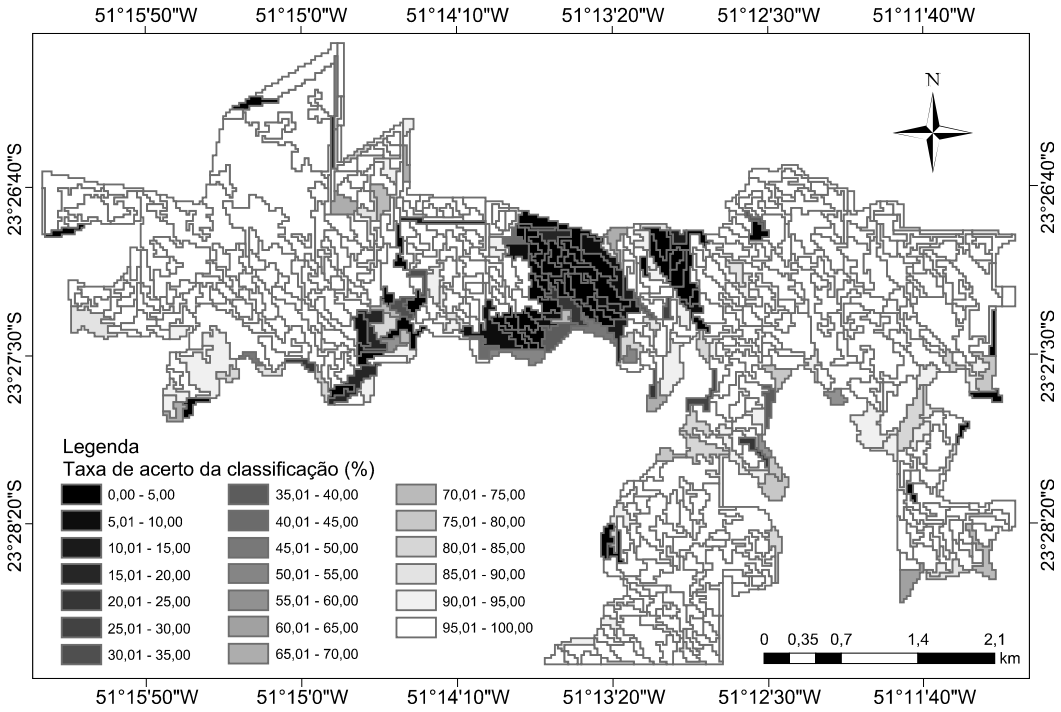

Figura 54 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}_{2009\rightarrow1989}$

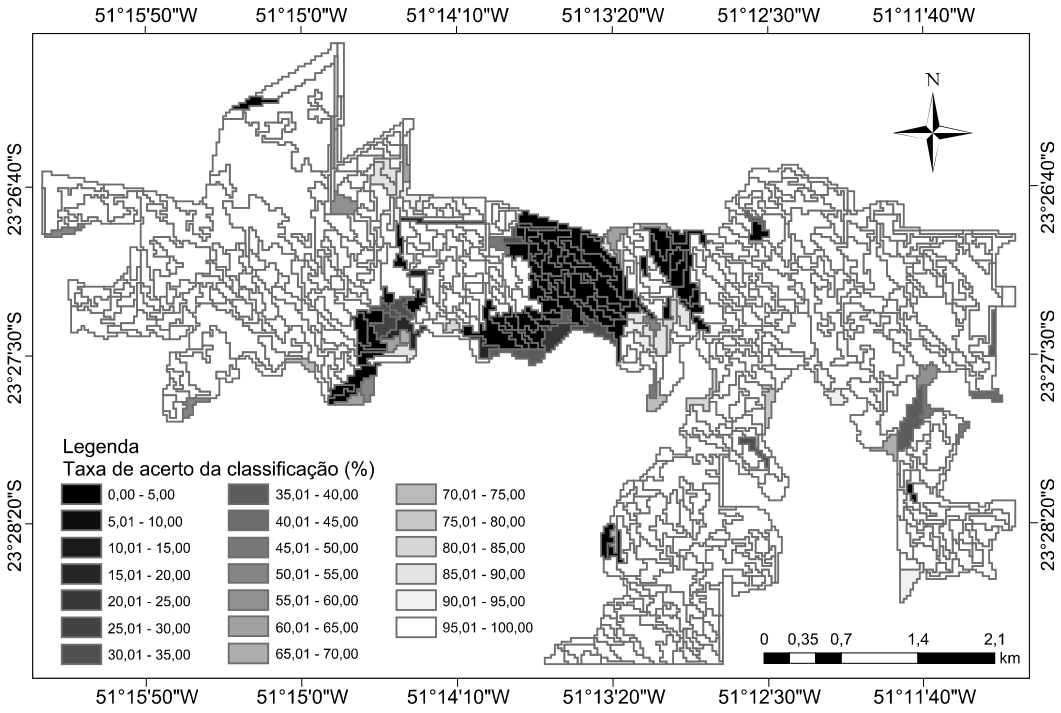

Figura 55 – Espacialização das taxas de acerto da classificação com base em $\mathbf{T}^{4}_{2009\rightarrow2004}$

5 CONCLUSÕES

A presente dissertação propôs dar sequência à investigação do tema interpretação de imagens multitemporais de sensoriamento remoto, a partir da abordagem de classificação multitemporal em cascata baseada em Cadeias de Markov Fuzzy (MOTA et al., 2007; FEITOSA et al., 2009; COSTA et al., 2009; FEITOSA et al. 2011), contemplando um aspecto pouco explorado em pesquisas anteriores: a avaliação da extrapolação das transformações temporais entre instâncias de tempo mais distantes, estimadas a partir da combinação das transformações temporais entre instâncias consecutivas.

A análise do método foi realizada através de uma série de experimentos onde o objetivo principal foi verificar o desempenho das classificações multitemporais em relação às classificações monotemporais, baseadas apenas em características espectrais.

Dentre as principais contribuições do presente trabalho em relação às pesquisas anteriores, estão:

- a investigação da combinação de CMF de períodos curtos para classificar imagens de períodos longos;
- a investigação do desempenho das classificações que utilizam matrizes de transição estimadas diretamente para um par de datas em comparação com as classificações com base nas matrizes de transição extrapoladas;
- a aplicação do método em série temporal com maior número de imagens;
- a utilização de uma região geográfica com características espectrais e dinâmica temporal distintas das regiões empregadas nas pesquisas anteriores; e
- a geração de mapas que possibilitaram verificar espacialmente os acertos e erros das classificações multitemporais.

De uma forma geral, pôde-se verificar, a partir dos resultados dos experimentos, que o uso das Cadeias de Markov Fuzzy contribuiu para a melhoria do desempenho do processo de classificação automática em imagens orbitais multitemporais, quando comparado com uma classificação monotemporal.

Para o modelo de transformação temporal de 5 anos ($\mathbf{T}_{k\rightarrow k+1}$) as classificações multitemporais apresentaram ganho médio de 0,22 pontos (Kappa). No momento em que se extrapolou o modelo de transformação temporal de 5 anos para classificar as imagens de 10, 15 e 20 anos, o desempenho das classificações multitemporais continuou a ser superior

(Tabela 24).

Foi possível observar, também, que existiram diferenças de comportamento do classificador multitemporal em períodos temporais curtos e longos. As classificações com base em matrizes estimadas para períodos curtos (5 anos - $\mathbf{T}_{k\rightarrow k+1}$), sempre apresentaram resultados superiores aos das classificações com base em matrizes estimadas para períodos longos ($\mathbf{T}^2_{k\rightarrow k+1}$ - 10 anos; $\mathbf{T}^3_{k\rightarrow k+1}$ - 15 anos; e $\mathbf{T}^4_{k\rightarrow k+1}$ - 20 anos).

Além disso, as classificações multitemporais com base em matrizes estimadas diretamente para um par de datas ($\mathbf{T}_{k\rightarrow k+2}$ - 10 anos; $\mathbf{T}_{k\rightarrow k+3}$ - 15 anos; e $\mathbf{T}_{k\rightarrow k+4}$ - 20 anos) apresentaram resultados superiores aos das classificações com base nas matrizes de transição extrapoladas ($\mathbf{T}^2_{k\rightarrow k+1}$ - 10 anos; $\mathbf{T}^3_{k\rightarrow k+1}$ - 15 anos; $\mathbf{T}^4_{k\rightarrow k+1}$ - 20 anos). Observa-se também que a superioridade da estimação direta frente à extrapolação se reduz com o aumento da distância temporal. Entretanto, mesmo com as diferenças de comportamento apresentadas, os resultados das classificações multitemporais sempre foram superiores aos das monotemporais, verificando-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 em uma região geográfica diferente da utilizada em pesquisas anteriores e, em ambos experimentos, apresentou resultados superiores .

Os resultados do presente trabalho poderão servir de motivação para a criação de sistemas de automação de classificação de imagens multitemporais com base no método proposto. O potencial de sua aplicação se justifica pela aceleração do processo de monitoramento do uso e cobertura da terra, considerando a melhoria obtida frente a classificações supervisionadas tradicionais. Assim, o método permite um melhor direcionamento para definição de estratégias de gestão e planejamento em benefício a população e do meio ambiente.

Como sugestões para trabalhos futuros podem ser mencionados:

- investigar o peso da inversão da série de imagens temporais no resultado da classificação, quando comparado com a série na sequência original;
- investigar o uso de diferentes parâmetros do Algoritmo Genético ou outros métodos de otimização na tentativa de melhorar estimação das matrizes de transição e os resultados das classificações;
- investigar se o aumento no número de bandas poderá contribuir para diminuição da confusão espectral, melhorando a classificação;

- comparar a espacialização das taxas de acerto das classificações multitemporais e monotemporais; e
- analisar o comportamento do método em imagens multitemporais de alta resolução.

REFERÊNCIAS

AACH, T..; KAUP, A.. Bayesian algorithms for adaptive change detection in image sequences using Markov random fields. *Signal Processing: Image Communication*, v. 7, n. 2, p. 147–160, 1995.

ALENCAR, A. A.; COSTA et al. Análise multitemporal do uso do solo e mudança da cobertura vegetal em antiga área agrícola da Amazônia oriental. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, VIII, 1996, Salvador. *Anais...* Salvador: INPE, 1996. p. 475-478.

ALVES, A. O.; MOTA, G. L. A.; COSTA, G. A. O. ; FEITOSA, R. Q. Interpretação de imagens multitemporais de sensoriamento remoto com base na combinação de cadeias de Markov fuzzy. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XV, 2011, Curitiba. *Anais...* Curitiba: INPE, 2011. p. 7309-7316.

ALVES, A. O.; PEREIRA NETO, O. C. Dinâmica do uso do solo do Parque Estadual Mata dos Godoy em Londrina-PR. In: FRERES, N. AP. *Análise Ambiental em Ciências da Terra*. 1ed., v.3. Londrina: EDUEL, 2010. Paginação irregular.

ALVES, A. O. *Dinâmica da paisagem do Parque Estadual Mata dos Godoy, a partir de imagens de satélite*. 2006. 30 f. Monografia (Especialização em Análise Ambiental) – Departamento de Geociências, Universidade Estadual de Londrina, Londrina, 2006.

AVRANCHENKOV, K. E.; SANCHEZ, E. Fuzzy Markov Chains and Decision-Making. *Fuzzy Optimization and Decision Making*, v. 1, n. 2, p. 143-159, 2002.

BHATTACHARYYA, A.. On a measure of divergence between two statistical populations defined by their probability distributions. *Bulletin of the Calcutta Mathematical Society*, v. 35, p. 99–109, 1943.

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

BRUZZONE, L.; COSSU, R.; PRIETO, D. Combining parametric and nonparametric classifiers for an unsupervised updating of land-cover maps- multiple classifier systems. *Springer-Verlag Berlin Heidelberg*, v. 1857, p. 290-299, 2000.

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. 211 p.

CLÉMENT, V.; GIRAUDON, G.; HOUZELLE, S.; SANDAKLY, F. Interpretation of Remotely Sensed Images in a Context of Multisensor Fusion Using a Multispecialist Archteture. *IEEE Transactions on Geoscience and Remote Sensing*, v. 31, n. 4, p. 779-791, 1993.

COHEN, J. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, XX, n. 1, p. 37–46, 1960.

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

COSTA, M. C. O.; FEITOSA, R. Q. ; MOTA, G. L. A. ; CAMPOS, V. O. Classificação Multitemporal de Imagens Utilizando Cadeias de Markov Nebulosas. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XIII, 2007, Florianópolis. *Anais...* Florianópolis: INPE, 2007, p. 5683-5690.

COSTA, G. A. O. ; FEITOSA, R. Q. ; MOTA, G. L. A.; PAKZAD, K.; COSTA, M. C.O. Um Método de Classificação Multitemporal em Cascata de Imagens de Sensoriamento Remoto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XIV, 2009, Natal. *Anais...* Salvador: INPE, 2009, p. 1291-1298.

COSTA, G. A. O. P. *Uma abordagem baseada em conhecimento para a interpretação automática de dados de sensoriamento remoto multi-data*. 2009. 149 f. Tese (Doutorado em Engenharia Elétrica) – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2009.

FEITOSA, R. Q. ; COSTA, G. A.O.P. ; MOTA, G. L. A. ; FEIJO, B. Modeling alternatives for fuzzy Markov chain-based classification of multitemporal remote sensing data. *Pattern Recognition Letters*, v. 32, p. 927-940, 2011.

FEITOSA, R. Q. ; COSTA, G. A.O.P. ; MOTA, G. L. A. ; PAKZAD, K.; COSTA, M. C. O. Cascade multitemporal classification based on fuzzy Markov chains. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 64, p. 159-170, 2009.

GLCF Global Land Cover Facility - Earth Science Data Interface (ESDI) at the Global Land Cover Facility. Disponível em: <http://glcfapp.glcf.umd.edu:8080/esdi/index.jsp>. Acesso em 10 out 2009.

GROWE, S. Knowledge based interpretation of multisensor and multitemporal remote sensing images. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. 32, part 7-4-3W6, p. 130–138, 1999.

IAP - Instituto Ambiental do Paraná. Plano de manejo do Parque Estadual Mata dos Godoy. 2002. Disponível em: <http://www.uc.pr.gov.br/modules/conteudo/conteudo.php?conteudo=27>. Acesso em 05 set 2009.

INPE - Instituto Nacional de Pesquisas Espaciais. Classificação de Imagens Segmentadas - Classificadores por regiões: Bhattacharya. Help do software SPRING, 2009a.
_____. Catálogo de imagens. Disponível em: < http://www.dgi.inpe.br/CDSR/>. Acesso em 15 out 2009b.

_____. Validação: Kappa. Help do software SPRING, 2009c.

JEON, B., LANDGREBE, D.A.. Classification with spatio-temporal interpixel class dependency contexts. *IEEE Transactions on Geoscience and Remote Sensing*, v. 30, n. 4 , p. 663–672, 1992.

JEON, B., LANDGREBE, D.A.. Decision fusion approach for multitemporal classification**.** *IEEE Transactions on Geoscience and Remote Sensing*, **v.** 37, n. 3, p.1227–1233, 1999.

KHAZENIE, N.; CRAWFORD, M.M. Spatio autocorrelated model for contextual classification. *IEEE Transactions on Geoscience and Remote Sensing*, v. 28, n. 4, p.1529–539, 1990.

LILLESAND, T.; KIEFER, R; CHIPMAN, J. W. *Remote sensing and image interpretation.* 5.ed. Nova Iorque: Jonh Wiley & Sons, 2004. 700 p.

MATHER, P. M. *Computer processing of remotely-sensed images:* an introduction. 3 ed. Nottingham: John Wiley & Sons, 2005. 324 p.

TSO, B.; MATHER, P. M. *Classification methods for remotely sensed data.* 2 ed. _____: CRC Press, 2009. 376 p.

MATHWORKS. MATLAB - The Language of technical computing. Disponível em <http://www.mathworks.com/products/matlab/?BB=1>. Acesso em 18 nov 2009.

MESQUITA JR., H. N.; BITENCOURT, M. D. Análise multitemporal de fragmentos de Cerrado do estado de São Paulo com censor orbital MODIS. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XI, 2003, Belo Horizonte. *Anais...* Belo Horizonte: INPE, 2003, p. 2815-2822.

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.

MOTA, G. L. A. *Interpretação baseada em conhecimento aplicada a imagens multitemporais de satélite de baixa resolução*. 2004. 210 f. Tese (Doutorado em Engenharia Elétrica) – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2004.

NIX, A.; VOSE, M. Modeling Genetic Algorithms with Markov Chains. *Annals of Mathematics and Artificial Intelligence*, v. 5, p. 79-88, 1992.

PRODES - Programa de Cálculo do Desflorestamento da Amazônia. Metodologia para o Cálculo da Taxa Anual de Desmatamento na Amazônia Legal. 2006. Disponível em: <http://www.obt.inpe.br/prodes/metodologia.pdf>. Acesso em 20 dez 2011.

SCHOWENGERDT, R. A. *Remote Sensing:* Models and Methods for Image Processing. 3 ed. Tucson: Academic Press Elsevier, 2007. 515 p.

SOLBERG, H.S.; TAXT, T.; JAINM A.K. A Markov random field model for classification of multisource satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing*, v. 34, n. 1, p. 100–113, 1996.

SOUTO, M. V. S.; AMARO, V. E.. Análise multitemporal quanto ao uso e ocupação do solo da região da Ponta do Tubarão, município de Macau/RN, utilizando técnicas de geoprocessamento. In.: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XI, 2003, Belo Horizonte. *Anais...* Belo Horizonte: INPE, 2003. p. 1649-1655.

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.