

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL**

**CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E METEOROLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO**

**UMA ABORDAGEM *FUZZY* NA DETECÇÃO AUTOMÁTICA DE  
MUDANÇAS DO USO DO SOLO USANDO IMAGENS DE FRAÇÃO E  
INFORMAÇÕES DE CONTEXTO ESPACIAL**

**Daniel Capella Zanotta**

**Orientador:** Prof. Vitor Haertel, PhD

**Porto Alegre, março de 2010**

# UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E METEOROLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

## UMA ABORDAGEM *FUZZY* NA DETECÇÃO AUTOMÁTICA DE MUDANÇAS DO USO DO SOLO USANDO IMAGENS DE FRAÇÃO E INFORMAÇÕES DE CONTEXTO ESPACIAL

**Daniel Capella Zanotta**

*Lic. e Bach. em Física (2007) - FURG*

**Orientador:** Prof. Vitor Haertel, PhD

### **Banca Examinadora:**

Prof. Dr. Carlos Vieira (UFV – Universidade Federal de Viçosa)

Prof. Dr. Luciano V. Dutra (INPE - Instituto Nacional de Pesquisas Espaciais)

Prof. Dr. João Luiz Dihl Comba (Instituto de Informática - UFRGS)

*Dissertação submetida ao Programa  
de Pós-Graduação em Sensoriamento  
Remoto da Universidade Federal do Rio  
Grande do Sul como requisito parcial para a  
obtenção do título de Mestre em  
Sensoriamento Remoto*

**Porto Alegre, março de 2010**

## **APRESENTAÇÃO**

Este trabalho foi desenvolvido no âmbito do Programa de Pós-Graduação em Sensoriamento Remoto do Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPSRM) da Universidade Federal do Rio Grande do Sul (UFRGS) durante o ano de 2008 e 2009, sob a orientação do Prof. Dr. Vítor Haertel.

## **AGRADECIMENTOS**

Antes de qualquer coisa gostaria de agradecer a Deus por tudo; passado presente e futuro. Ao professor Vitor Haertel, orientador, mas também de forma justa, co-autor desse trabalho, pelo profissionalismo e amizade dedicados o tempo todo juntamente com sua sapiência e entusiasmo contagiante pela ciência. A ele agradeço também pelo tópico desenvolvido nesse estudo, o qual se mostrou desafiador ao mesmo tempo em que revelava crescente pertinência dentro do estado atual da arte;

Aos meus pais Maria Odete e Geraldo, meus primeiros professores, que nesses dois anos, mesmo a distância, desempenharam o papel de forma responsável, apoiando sempre que preciso e ajudando nas decisões difíceis, além da base educacional sólida que vem me sendo proporcionada ao longo da vida;

Aos colegas do CEPSRM, três gerações que tiveram uma convivência extraordinária comigo, e aos quais eu devo muito por esse trabalho, especialmente Thiago e Rafaela (turma anterior), Juliana S., Guilherme, Alan, Zé, Fabrício (minha turma), Atilio e Juliana C. (turma posterior);

Aos meus familiares da região metropolitana que funcionaram como uma válvula de escape sempre que precisei. Não muito longe, aos meus irmãos de Porto Alegre, essa fauna tão divertida habitante do “apê 15” que me esperava todos os dias com o vídeo-game ligado e alguma história surpreendente a ser contada, provocando o atraso do trabalho, mas bem acredito, melhor qualificando-o. Agradeço a eles pelos momentos de descontração, amizade e companheirismo;

Aos meus tios Paulo e Angélica que contribuíram diretamente com esse trabalho da forma que lhes era possível;

Ao CNPq pelo suporte financeiro na forma de bolsa de estudos integral;

À UFRGS, meu segundo lar, que sempre proporcionou as mais favoráveis condições possíveis para a execução deste estudo. À Dona Carmem, aos professores Ducati, Marcelo, Rita, Laurindo e Dejanira pelos ensinamentos e discussões muito gratificantes, e à coordenadora do curso, prof<sup>a</sup>. Silvia B. A. Rolim, por ser não só uma professora, mas sim por se tornar uma amiga incondicional acima de tudo.

*“This most beautiful system [The Universe]  
could only proceed from the dominion  
of an intelligent and powerful Being.”*

**Sir Isaac Newton**

# UMA ABORDAGEM *FUZZY* NA DETECÇÃO AUTOMÁTICA DE MUDANÇAS DO USO DO SOLO USANDO IMAGENS DE FRAÇÃO E INFORMAÇÕES DE CONTEXTO ESPACIAL

Daniel Capella Zanotta

Orientador: Prof. Vitor Haertel, PhD

## RESUMO

Nesta dissertação está proposta uma metodologia para fins de detecção de mudanças do uso do solo em imagens multitemporais de sensoriamento remoto. Em lugar de classificar os pixels de imagens que cobrem uma cena, em duas classes exaustivas e mutuamente excludentes (mudança, não-mudança), propõe-se adotar uma abordagem do tipo *fuzzy*, na qual são estimados os graus de pertinência às classes mudança e não-mudança. Com este objetivo adota-se aqui uma abordagem em nível de sub-pixel na estimação dos graus de pertinência para cada pixel. Esta abordagem se mostra mais adequada para fins de modelagem do que ocorre em cenas naturais, onde as alterações que acontecem ao longo de um período de tempo tendem a apresentar uma variação contínua em lugar de discreta. Em uma segunda etapa, os graus de pertinência estimados recebem um ajustamento adicional por meio da introdução de informações de contexto espacial. A metodologia proposta foi testada por meio de três experimentos, um empregando uma imagem sintética e dois utilizando imagens reais. A partir da análise quantitativa dos resultados e comparação com estudos semelhantes, comprova-se a adequação da metodologia proposta.

Palavras-chave: detecção de mudanças *fuzzy*, modelo linear de mistura, alteração em sub-pixel, contexto espacial

# **A FUZZY APPROACH TO LAND USE AUTOMATIC CHANGE DETECTION USING FRACTION IMAGES AND SPATIAL CONTEXT INFORMATION**

Daniel Capella Zanotta

Orientador: Prof. Vitor Haertel, PhD

## **ABSTRACT**

In this dissertation it is proposed a new methodology to land use change detection in remote sensing multitemporal image data. Rather than applying a rigid labeling of the pixels in the image data into two classes (change, no-change), we propose estimating the degrees of membership to classes change and no-change in a fuzzy-like fashion. To this end, a sub-pixel approach is implemented to detect the degree of change in every pixel. This methodology aims at modeling natural scenes in a more realistic way, since changes in natural scenes tend to occur in a continuum rather than in a sharp distinctive way. In a second step, the estimated values for the degrees of membership are further refined by means of spatial context information. Three experiments were performed to test the proposed methodology, one employing synthetic data and two using real image data. From the quantitative analysis of the results and from similar studies we can prove the adequacy of the proposed methodology.

*Key-words:* fuzzy change detection, linear mixture model, sub-pixel change, spatial context

# SUMÁRIO

<b>1</b>	<b>Introdução</b>	<b>1</b>
<b>2</b>	<b>Revisão Bibliográfica</b>	<b>5</b>
2.1	O conceito de pixel mistura	6
2.2	Abordagens ao problema da mistura de densidades	8
2.3	Classificador de Bayes e Máxima Verossimilhança	10
2.4	Inserção de informações de contexto espacial nos resultados classificados	11
<b>3</b>	<b>metodologia</b>	<b>12</b>
3.1	Introdução	12
3.2	Pré-processamento das imagens	14
3.3	Registro espacial das imagens	15
3.4	Geração das Imagens de Fração	15
3.5	Estimação dos valores iniciais para o algoritmo EM	16
3.6	Aplicação do algoritmo EM	17
3.7	Função de decisão Bayesiana para o cálculo dos graus de pertinência	19
3.8	Inserção de informações de contexto espacial	20
<b>4</b>	<b>Testes e Experimentos</b>	<b>24</b>
4.1	Introdução	24
4.2	Dados imagem utilizados	24
4.3	Área de estudo selecionada	25
4.4	Produção das imagens fração	26
4.5	Produção da imagem sintética	28
4.6	Produção das imagens diferença	31
4.7	Resultados relativos ao experimento realizado com dados sintéticos	34
4.7.1	Imagem de referência	34
4.7.2	Estimação dos parâmetros das distribuições e das probabilidades <i>a priori</i> das classes mudança e não-mudança	35
4.7.3	Produção das imagens de mudanças ocorridas	39
4.7.4	Inserção de informações de contexto espacial de acordo com a metodologia proposta	41
4.8	Experimento empregando imagens <i>Landsat 5-TM</i> reais para as duas datas	44
4.8.1	Descrição das imagens usadas	44
4.8.2	Produção das imagens de diferença	45
4.8.3	Estimação dos parâmetros das distribuições e das probabilidades <i>a priori</i> das classes mudança e não-mudança	47
4.8.4	Produção das imagens de mudanças ocorridas	51
4.8.5	Inserção do contexto espacial de acordo com a metodologia proposta	53
4.9	Experimento empregando imagens CBERS-2B de região atingida por queimada no Pantanal	56
4.10	Custo computacional	58



<b>5 Conclusões e Sugestões .....</b>	<b>60</b>
5.1 Conclusões .....	60
5.2 Sugestões .....	61
<b>Referências Bibliográficas .....</b>	<b>62</b>
<b>6 Apêndice: Código Fonte (linguagem matlab) .....</b>	<b>65</b>
1) Função para fracionamento da imagem .....	65
2) Função acelerada para fracionamento da imagem a partir de segmentos da imagem e operações paralelas do tipo <i>multi-core</i> .....	66
3) Função para resolver o problema da mistura das densidades de probabilidade (algoritmo EM) .....	68
4) Função para classificação por um suporte Bayesiano seguindo uma lógica <i>Fuzzy</i> .....	71
5) Função de inserção de informações de contexto espacial pelo método de relaxação proposto .....	73
6) Função usada para reorganizar a imagem do formato Erdas 7.4 para o formato retangular. ....	78

# 1 INTRODUÇÃO

O sensoriamento remoto se constitui em uma técnica que tem evoluído muito nas últimas décadas, seja pelo lançamento de novos sensores orbitais cada vez mais modernos, pelo avanço das técnicas de processamento e interpretação de dados imagem adquiridos pelos sistemas sensores ou pela disponibilização de máquinas capazes de processar de forma rápida o volume de dados adquirido pelas diversas plataformas orbitais. Sua alta cobertura espaço-temporal revolucionou a maneira como a pesquisa é conduzida e abriu novas possibilidades para o entendimento e acompanhamento de fenômenos terrestres em escala local e global.

Nos últimos anos tem se notado um crescimento no interesse pelo desenvolvimento de técnicas automáticas para detecção de mudanças através de imagens multitemporais de sensoriamento remoto. Esse interesse é impulsionado pelo grande número de aplicações em que os métodos de detecção de mudanças a partir de imagens coletadas por sensores orbitais podem ser empregados, tais como monitoramento de desastres ambientais, queimadas, desmatamentos, estudos urbanos, monitoramento florestal etc. Normalmente a detecção de mudanças envolve a análise de duas imagens multiespectrais cobrindo a mesma área, mas adquiridas em datas distintas. Essa análise permite a detecção de alterações ocorridas na cobertura do solo durante o período considerado.

Na literatura referente ao sensoriamento remoto, duas principais abordagens ao problema da detecção de mudanças têm sido propostas: o método supervisionado e o método não supervisionado. O método de classificação supervisionado está centrado na análise comparativa entre imagens temáticas cobrindo a cena em questão e obtidas a partir da classificação de imagens multiespectrais coletadas em datas distintas. Este procedimento requer portanto amostras de treinamento coletadas *in situ* para a caracterização das diferentes classes de cobertura do solo presentes na cena que está sendo analisada. Já no método não supervisionado, a detecção é feita pela comparação direta entre duas imagens multitemporais sem fazer uso de qualquer outro dado adicional. Nesse caso o processo se dá pela aplicação de operações matemáticas e métodos estatísticos não supervisionados. Embora o método supervisionado exiba algumas vantagens em comparação com o método não-supervisionado (ex: determinação do tipo de mudança ocorrida), a produção de dados multitemporais de verdade terrestre (amostras de treinamento) é geralmente uma tarefa de difícil execução e de custo elevado. Conseqüentemente, o uso de métodos não supervisionados na detecção de

mudanças tem sido largamente explorado pelos pesquisadores no desenvolvimento de seus trabalhos.

Nos métodos não supervisionados, a maioria das abordagens propostas na literatura faz uso das chamadas imagens diferença. No caso de imagens multiespectrais, (Singh, 1989; Fung, 1990) a imagem-diferença é obtida pela subtração, pixel a pixel, das bandas correspondentes em dois conjuntos de imagens multitemporais. A escolha das bandas espectrais dependerá do tipo específico de alteração que se deseja detectar (ex: alterações na vegetação, tipo de solo, manejo etc.).

Em situações reais, as imagens diferença, assim obtidas, mostram uma ampla gama de valores, correspondendo tanto a grandes quanto a pequenas mudanças na cobertura do solo durante o período de tempo em questão, conferindo à imagem de diferenças uma considerável variância estatística. Devido a fatores como erro no registro espacial das duas imagens, ruído do sistema sensor, diferença na composição atmosférica e da órbita solar no momento da aquisição das imagens, existirão alguns pixels na imagem de diferenças que não devem ser interpretados como mudanças, mas sim como ruídos inerentes a um ou alguns dos fatores mencionados acima. Com o objetivo de separar as alterações significativas na cobertura do solo de alterações não significativas ou resultantes de ruído, diversos autores tem proposto o uso de limiares que servem para definir duas classes na imagem de diferenças: mudança e não-mudança. A principal dificuldade nesta abordagem consiste justamente na definição de um critério para a seleção desse limiar. Em geral é neste estágio que as abordagens ao problema conforme relatadas na literatura por diferentes autores tomam rumos distintos. Várias propostas neste sentido podem ser encontradas, porém, a definição de uma fronteira entre as duas classes incorre, em maior ou em menor grau, em critérios empíricos ou arbitrários. A principal dificuldade reside no fato de que em cenas naturais, as alterações ocorrem de uma forma gradual e contínua, fato este que torna muito difícil a definição objetiva de um limiar separando rigidamente a classe mudança da classe não-mudança. Nesta dissertação investiga-se uma abordagem que tem como principal objetivo resolver esta dificuldade ao propor uma abordagem *fuzzy* ao problema de detecção de mudanças a partir de imagens multitemporais.

Recentemente alguns trabalhos, como Haertel *et al.* (2004), fizeram uso do conceito de pixel mistura para fins de detecção de mudanças a partir de imagens multitemporais. O emprego de imagens de fração no problema de detecção de mudanças permite a efetivação

desta análise em nível de sub-pixel e, por esta razão, mostra-se especialmente adequado a uma abordagem *fuzzy*, conforme a proposta aqui investigada. O fenômeno de mistura em pixels ocorre quando um mesmo pixel compreende duas ou mais classes distintas, denominadas, neste contexto, de componentes (*endmembers*). A partir de imagens multiespectrais, pode-se derivar um novo conjunto de dados com as chamadas imagens-fração, que por sua vez informam em cada pixel a fração ocupada por cada uma das componentes do terreno, como por exemplo, vegetação, solo, sombra/água entre outras. Esta abordagem permite a estimação de alterações temporais ocorridas diretamente nas frações, isto é, variações dos valores percentuais das componentes em nível de sub-pixel, permitindo que as mudanças sejam definidas por graus de pertinência às classes mudança e não-mudança, eliminando a necessidade da definição de um limiar rígido separando as duas classes.

Com a finalidade de aumentar a confiabilidade nos valores estimados para os graus de pertinência de pixels individuais as classes mudança e não-mudança, pode-se refinar os valores estimados para os graus de pertinência pela inclusão de informações de contexto espacial. Esta inclusão é justificada pela existência de correlação espacial em cenas naturais no que se refere a alterações na cobertura do solo (Tso e Mather, 2001). Informações derivadas de contexto espacial podem ser obtidas a partir de atributos espectrais, espaciais ou até temporais. O uso adequado do contexto permite eliminar possíveis ambigüidades, recuperar informações perdidas, e corrigir erros (Li, 1995). Explorando o conceito de contexto espacial, os pixels passam a ser tratados não isoladamente, mas em relação aos seus vizinhos. Assim, a relação entre o pixel de interesse e sua vizinhança é tratada como sendo espacialmente dependente do ponto de vista estatístico (Tso e Mather, 2001). Este fato vem sendo explorado por alguns autores como uma informação adicional capaz de contribuir na acurácia no processo de classificação de imagens digitais em geral, além de facilitar consideravelmente a visualização de um mapa de mudanças por apresentar objetos mais homogêneos e sem a presença do efeito *salt and pepper* gerado por ruídos aleatórios.

O objetivo dessa dissertação consiste portanto no desenvolvimento de uma metodologia para fins de análise de imagens multitemporais de sensores remotos ópticos (passivos) com o intuito de detectar eventuais mudanças ocorridas no período compreendido entre a aquisição das imagens. A metodologia aqui proposta consiste nas seguintes etapas. Dados dois conjuntos de imagens multiespectrais cobrindo a mesma cena, mas obtidas em diferentes datas, geram-se imagens de fração para cada uma das duas datas, com base em um número adequado de componentes (*endmembers*) que representem a cena. A etapa seguinte

consiste em obter as imagens de diferença de cada uma das componentes. Logo após, estima-se, para cada pixel, os graus de pertinência as classes mudança e não-mudança. Esta estimativa é feita em uma abordagem Bayesiana, com os parâmetros associados às classes mudança e não-mudança (vetor de médias e matriz de covariância) estimados automaticamente com o auxílio do algoritmo *Expectation-Maximization* (EM). Em uma etapa final os graus de pertinência são ajustados com o auxílio de informações de contexto espacial, implementados em uma abordagem iterativa de relaxação.

Esta dissertação está organizada da seguinte maneira: no capítulo 2 é feita uma revisão relativa ao atual estado do conhecimento na área abrangida pelo trabalho. No capítulo 3 é apresentada em detalhes a metodologia proposta. Os princípios que servem de base à proposta apresentada e investigada nesta dissertação bem como a metodologia adotada em sua implementação são apresentados e discutidos. As novas idéias propostas são ilustradas e testadas no capítulo 4 por experimentos envolvendo dados reais e dados sintéticos. Imagens sintéticas apresentam a vantagem de permitirem testes em um ambiente totalmente controlado, enquanto imagens de cenas naturais permitem avaliar a metodologia proposta em condições reais. Finalmente, no capítulo 5 é apresentada uma análise geral da proposta desta dissertação e são colocadas as principais conclusões.

## 2 REVISÃO BIBLIOGRÁFICA

O desenvolvimento de novas técnicas automáticas para fins de detecção de mudanças a partir de imagens multitemporais de sensoriamento remoto tem sido alvo de diversos trabalhos nas últimas décadas. Trabalhos considerados clássicos foram apresentados por Singh (1989) e Fung (1990), onde uma revisão de diferentes métodos usados para detecção de mudanças pode ser encontrada. Uma análise mais geral de diferentes algoritmos usados é encontrada em Radke *et al.* (2005).

Estudos realizados principalmente nas duas últimas décadas evidenciaram questões fundamentais envolvidas no processo de detecção de mudanças. Trabalhos como Xiaolong e Khorram (1998) e Bruzzone e Cossu (2003) investigaram maneiras para reduzir os efeitos do erro no registro espacial das imagens utilizadas. Métodos para detecção de mudanças empregando imagens em alta resolução espacial foram investigados por Bovolo (2008) e Dalla Mura *et al.* (2008). Nesse contexto, algoritmos de segmentação de imagens são geralmente usados para formar objetos para a posterior detecção de mudanças, no caso da classificação supervisionada. Uma abordagem que tem mostrado particular eficiência é baseada na análise de vetores diferença (*Change Vector Anaysis*) ou CVA. Essa técnica foi originalmente proposta por Malila (1980) para aplicações em monitoramento de florestas. Esta mesma abordagem foi aplicada em ambientes marinhos apresentando resultados satisfatórios (Michalek *et al.* 1993). Um método automático para detecção de mudanças em áreas agrícolas foi proposto por Serpico *et al.* (1996). No trabalho, os autores investigam uma técnica para estimar iterativamente as probabilidades de transições entre classes temáticas. Um método automático para detecção de mudanças seguindo uma lógica de classificação Bayesiana não supervisionada foi proposto por Bruzzone e Prieto (2000), onde os autores propõem o uso do algoritmo *Expectation-Maximization* (EM) para estimar automaticamente um limiar separando a classe mudança da classe não-mudança. Schneider e Fernandes (2003) investigaram o uso de conceitos de entropia em imagens *Synthetic Aperture Radar* (SAR) visando à detecção automática de mudanças ocorridas em imagens desse tipo. Ainda tratando de imagens SAR, Bazi *et al.* (2005) apresenta um método não supervisionado especificamente orientado para a análise de imagens multitemporais. Outro método de considerável importância, baseado em um classificador semi-supervisionado usando os conceitos de *Support Vector Machine* (SVM), foi proposto em Bovolo *et al.* (2008). Um classificador

multitemporal não paramétrico é apresentado em Bruzzone *et al.* (2004) para detectar transições na cobertura do solo. No estudo, um conjunto de classificadores multitemporais é definido e integrado no contexto de um sistema de classificação múltipla. Hsieh *et al.* (2006) aborda o problema da detecção de mudanças a partir de uma análise em nível de sub-pixel usando, entre outros, atributos como inclinação e elevação do terreno na classificação.

As subseções a seguir apresentam a revisão dos conceitos mais particulares necessários ao desenvolvimento desta dissertação para fins de obtenção da imagem de diferenças, classificação Bayesiana a partir de parâmetros definidos automaticamente, e por fim, inserção de informações do contexto espacial pelo método de relaxação proposto. Uma abordagem mais fundamentada e sistemática do processo é apresentada no capítulo 3.

## 2.1 O conceito de pixel mistura

No processo de detecção de mudanças na cobertura do solo a partir de dados em imagens multitemporais podem ser empregadas diretamente imagens multiespectrais ou imagens obtidas por transformações tais como índice de vegetação por diferença normalizada (NDVI), componentes principais (Singh, 1989), entre outras possíveis. Nesta dissertação as imagens de diferenças são produzidas a partir da subtração de componentes das imagens fração geradas a partir das imagens multiespectrais (Haertel *et al.* 2004). Esta abordagem apresenta duas vantagens principais: (1) permite uma análise em nível de sub-pixel e (2) elimina a necessidade de normalização radiométrica das imagens adquiridas em datas diferentes.

O método de fracionamento de imagens particularmente seguido neste trabalho emprega a abordagem descrita nos trabalhos de Haertel e Shimabukuro (2005), Haertel *et al.* (2004) e Shimabukuro e Smith (1991). Os trabalhos citados fazem uso do Modelo Linear de Mistura Espectral (MLME) para estimar as frações das componentes de mistura (*endmembers*) de cada pixel da imagem. O MLME assume que a resposta espectral de cada pixel pode ser modelada por uma combinação linear das respostas espectrais de cada componente, ponderada pela fração da área que essa componente ocupa dentro do pixel (Haertel e Shimabukuro, 2005). As frações componentes do pixel são aproximadas pelo modelo como mostrado da Figura 1.


O MLME é representado por  $p$  equações lineares para  $m$  frações desconhecidas:

$$R_k = \sum_{j=1}^m r_{j,k} f_j + v_k \quad (k = 1, \dots, p) \quad (2.1)$$

onde  $R_k$  representa a resposta espectral de um pixel na banda  $k$ ,  $r_{j,k}$  corresponde à resposta espectral da componente  $j$  na banda  $k$ ,  $f_j$  a fração do pixel ocupada pela componente  $j$ ,  $v_k$  o erro residual do modelo,  $p$  é o número de bandas espectrais em uso e  $m$  o número de componentes consideradas. Para  $p < m$  o sistema é tido como indeterminado; para  $p = m$  o sistema é determinado e apresenta uma solução exata; para  $p > m$  o sistema é sobredeterminado, podendo ser resolvido para as frações ( $f_j$ ) utilizando o método dos mínimos quadrados, sujeito às seguintes restrições:

$$\begin{aligned} 0 \leq f_j \leq 1 \quad \forall j \\ \sum_{j=1}^m f_j = 1 \end{aligned} \quad (2.2)$$

Os valores da equação (2.1) devem ser seleccionados de forma a representar da melhor forma possível as componentes (*endmembers*) para a imagem em questão.



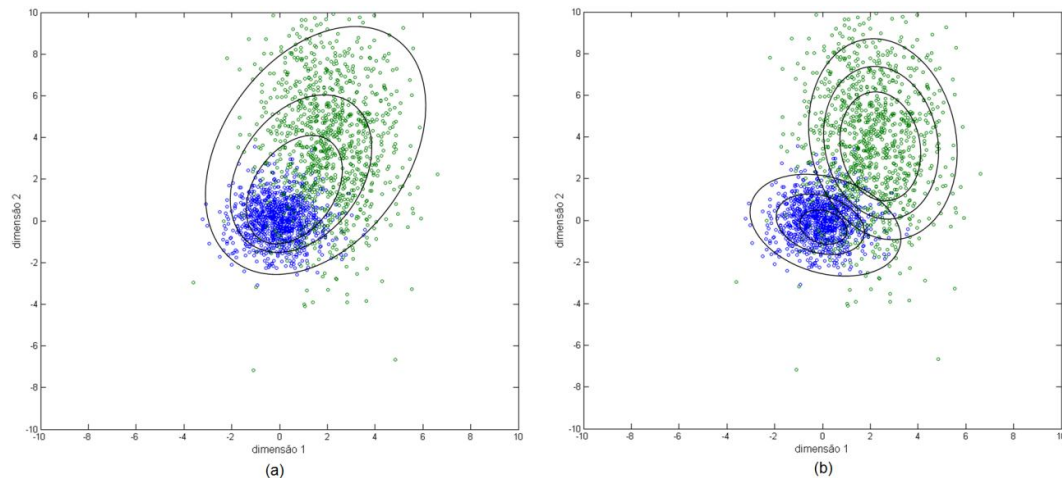
**Figura 1 - Representação do Modelo Linear de Mistura Espectral (MLME): (a) descrição real das porções existentes na área delimitada pelo pixel, (b) resposta espectral do sensor para a área correspondida pelo pixel e (c) resultado do fracionamento pelo MLME nas componentes de vegetação, solo e sombra/água.**

O resultado do fracionamento contará com um número de imagens igual ao número de componentes escolhidas para representar a região.



## 2.2 Abordagens ao problema da mistura de densidades

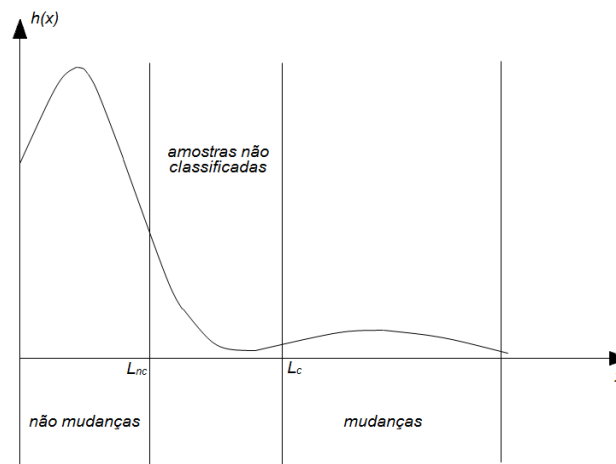
Um ponto crucial no processo de detecção de mudanças a partir de imagens de diferença reside na necessidade da estimação de um limiar de separação entre as classes mudança e não-mudança. Bruzzone e Prieto, (2000), propõe uma abordagem estatística a este problema empregando o algoritmo EM para estimar os parâmetros relacionados às classes. A abordagem estatística do problema envolvendo a mistura de densidades a partir desse método foi extensivamente estudada e pode ser encontrada na literatura especializada (Duda *et al.* 2001; Theodoridis e Koutroumbas, 2003; Bishop, 2006). O algoritmo EM pode ser usado para fins de estimação dos parâmetros (vetor de médias, matriz de covariâncias e probabilidade *a priori*) em misturas de distribuições. A Figura 2 ilustra como dois conjuntos de dados misturados e com distribuições gaussianas (a), são separados em duas classes distintas (b) pelo algoritmo EM. As elipses estão posicionadas de maneira a compreender o mesmo número de pontos entre as fronteiras. Este processo pode ser empregado para estimar os parâmetros relativos às classes mudança e não-mudança.



**Figura 2 - Processo de separação de densidades de probabilidade pelo algoritmo EM: distribuições gaussianas de duas classes misturadas (a) e a separação resultante da aplicação do algoritmo informando os parâmetros estatísticos das distribuições de probabilidade (b).**

No caso de detecção de mudanças, o histograma dos valores absolutos da imagem de diferenças apresenta uma distribuição bimodal (Figura 3). Duas gaussianas caracterizam as

classes de mudança e não-mudança. Pixels que não sofreram mudanças aparecem com valores baixos (alterações próximas de zero). Estes valores são causados por erros residuais (erros no registro das imagens, erros na produção das imagens fração) e pequenas alterações na cobertura do solo que não tem interesse prático. As alterações efetivas aparecem com valores maiores, resultado das grandes diferenças nos valores registrados pelos pixels correspondentes nas imagens das duas datas. Através do algoritmo EM, as duas distribuições gaussianas podem ser identificadas e separadas automaticamente através da estimação dos parâmetros estatísticos que as caracterizam. Esta abordagem permite a estimação mais confiável da fronteira ou limiar separando as duas classes. Limiares estimados empiricamente ( $L_c$  e  $L_{nc}$  na Figura 3)<sup>1</sup> passam a ter valores mais acurados, resultando em apenas uma fronteira de separação entre as classes, extinguindo a região de amostras não classificadas (Bruzzone e Prieto, 2000).



**Figura 3 - Representação esquemática da estratégia empírica de limiarização aplicada para o histograma da imagem de diferenças  $h(x)$ .  $L_{nc}$  e  $L_c$  representam os limiares das classes não-mudança e mudança respectivamente.**

*Fonte: Adaptado de Bruzzone e Prieto, 2000.*

O algoritmo EM foi proposto e explicado pela primeira vez em Dempster *et al.* (1977). Neste trabalho, os autores esclarecem que o método foi sugerido diversas vezes anteriormente por outros autores, mas este artigo da década de 70 generalizou e desenvolveu a teoria. O processo parte de estimativas iniciais (que podem ser pouco precisas) dos parâmetros

<sup>1</sup> Na verdade o índice  $c$  de  $L_c$  se refere a *change*; da mesma forma  $nc$  se refere a *no change*. Essa notação foi escolhida para padronizar os trabalhos que vêm sendo produzidos pelo grupo de pesquisa.

estatísticos e das probabilidades *a priori* [ $\boldsymbol{\mu}_i$ ,  $\boldsymbol{\Sigma}_i$  e  $P(\omega_i)$ ] que caracterizam as distribuições componentes da mistura, onde  $\boldsymbol{\mu}_i$  e  $\boldsymbol{\Sigma}_i$  representam respectivamente o vetor de médias e a matriz de covariâncias, e  $P(\omega_i)$  corresponde à probabilidade *a priori*; o índice  $i$  se refere à classe em questão ( $\omega_i$ ). Essas informações podem ser aplicadas em classificadores paramétricos, como por exemplo, o classificador de Bayes e o seu derivado, o classificador de Máxima Verossimilhança (Duda *et al.* 2001).

## 2.3 Classificador de Bayes e Máxima Verossimilhança

A efetiva utilização do classificador de Bayes requer que seja conhecida a forma genérica da função densidade de probabilidade  $p(\mathbf{X}|\omega_i)$ . A experiência prática utilizando dados multiespectrais de sensoriamento remoto tem mostrado que a função densidade de probabilidade multivariada com distribuição normal (Gaussiana) descreve bem o comportamento destes dados. A função de probabilidade *a posteriori*  $P(\omega_i|\mathbf{X})$  pode ser expressa utilizando-se o teorema de Bayes (Richards e Jia, 1999):

$$P(\omega_i|\mathbf{X}) = \frac{p(\mathbf{X}|\omega_i) \cdot P(\omega_i)}{p(\mathbf{X})} \quad (2.3)$$

onde  $P(\omega_i)$  representa a probabilidade *a priori* para a classe  $\omega_i$ ,  $p(\omega_i|\mathbf{X})$  representa a probabilidade *a posteriori* da classe  $i$  e  $p(\mathbf{X}|\omega_i)$  representa o valor da função densidade de probabilidade de  $\mathbf{X}$  condicional à classe  $\omega_i$ . Sendo  $p(\mathbf{X})$  apenas um fator de escala que pode ser considerado comum a todas as classes, permitindo a sua retirada da equação sem que o resultado da classificação seja alterado. Assim,

$$\mathbf{X} \in \omega_i \text{ se } p(\mathbf{X}|\omega_i) \cdot P(\omega_i) > p(\mathbf{X}|\omega_j) \cdot P(\omega_j) \forall i \neq j \quad (2.4)$$

é conhecida como a regra de decisão de Bayes. No caso de não se possuir informações suficientes sobre as probabilidades *a priori* das classes, assumem-se valores iguais para as probabilidades *a priori*. A regra de classificação resultante dessa aproximação é conhecida como Máxima Verossimilhança.

Para possibilitar a implementação efetiva da função de decisão de Bayes, deve-se optar pela descrição de uma função densidade de probabilidade. No caso estudado, a aproximação mais adequada é representada pela função normal multivariada:

$$p(\mathbf{X} | \omega_i) = (2\pi)^{-p/2} |\Sigma_i|^{-1/2} \exp\left[-\frac{1}{2}(\mathbf{X} - \boldsymbol{\mu}_i)' \Sigma_i^{-1} (\mathbf{X} - \boldsymbol{\mu}_i)\right] \quad (2.5)$$

onde  $p(\mathbf{X}|\omega_i)$  representa a função de decisão para cada classe de alteração;  $p$  representa a dimensionalidade dos dados;  $\Sigma_i$  representa a matriz de covariância;  $\boldsymbol{\mu}_i$  a média;  $P(\omega_i)$  a probabilidade *a priori* para a classe  $\omega_i$ , que devem ser estimados para cada uma das classes presentes na cena analisada.

## 2.4 Inserção de informações de contexto espacial nos resultados classificados

Assim como na classificação temática de imagens de sensoriamento remoto, os diferentes métodos automáticos para detecção de mudanças vêm investindo consideravelmente os seus esforços em uma forma de refinar a classificação final. Com este objetivo, outras fontes de informação têm sido exploradas por vários autores além das multiespectrais originais. Uma categoria de informação que apresenta um bom potencial consiste na correlação espacial que ocorre em imagens de cenas naturais. Se essa dependência puder ser estimada de alguma maneira para um dado conjunto de dados, esta informação pode ser usada para tornar os dados pós-classificação mais coerentes. Métodos para inserir esse tipo de informação em imagens classificadas foram discutidos por alguns autores (Therrien, 1989). A relaxação probabilística foi investigada por Di Zeno *et al.* (1986) para incrementar a acurácia em classificações temáticas. Estritamente falando em detecção de mudanças, alguns trabalhos vêm explorando esse fato (Bruzzone e Prieto, 2000; Melgani e Serpico, 2003; Ghosh *et al.* 2007). Os dois primeiros trabalhos fazem uso de Campos Randômicos de Markov (*Markov Random Fields*, MRF) para explorar as informações de contexto espacial, enquanto o último implementa a técnica a partir de redes neurais aliado a outros métodos. Em geral os métodos utilizados pelos autores apresentam bom desempenho, melhorando consideravelmente os resultados da pré-classificação.

É interessante ressaltar que nos trabalhos acima referenciados as metodologias propostas são aplicadas a imagens binárias, correspondentes às classes mudança e não-mudança.

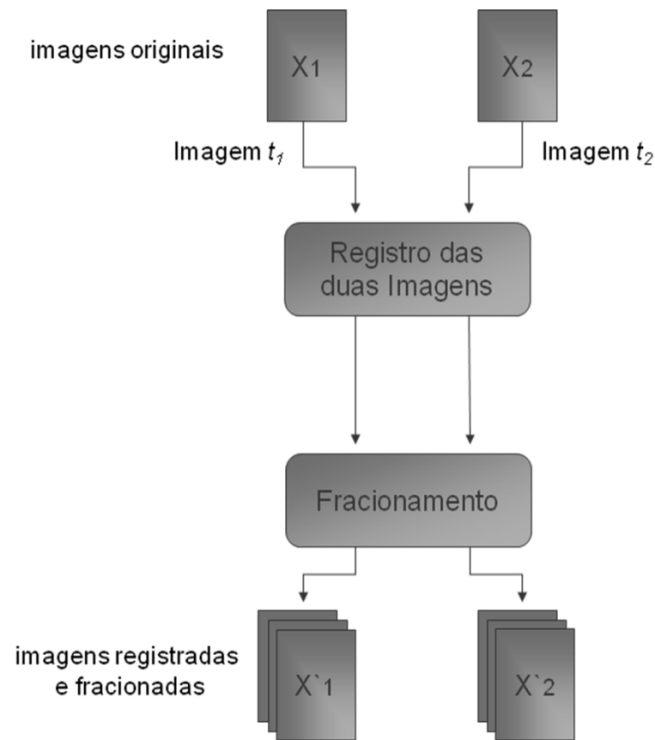
## 3 METODOLOGIA

### 3.1 Introdução

Além das técnicas tradicionais de processamento de imagens digitais de sensoriamento remoto, as técnicas e métodos descritos no Capítulo 2 servem de base metodológica para as técnicas propostas nesta dissertação. Os procedimentos mais consolidados como o funcionamento do algoritmo EM e as propriedades da função de decisão dentro de uma abordagem Bayesiana serão mantidos originais, sendo apenas modificados alguns aspectos referentes à notação. Com relação à inserção das informações de contexto espacial uma nova abordagem é proposta nessa dissertação, empregando uma versão modificada da metodologia de relaxação probabilística proposta em Di Zenzo *et al.* (1986). Naquele trabalho, os autores empregam contexto espacial como uma técnica de pós-classificação. Nesta dissertação esta abordagem é empregada para refinar os graus de pertinência de cada pixel às classes mudança e não-mudança. Uma adequação dos algoritmos apresentados naquele trabalho se faz necessária com vistas a adaptar o método para imagens *fuzzy*, isto é, imagens numéricas contendo valores contínuos no intervalo  $[0, 1]$  em lugar de valores discretos associados a imagens temáticas. Um diagrama esquemático do processo geral de detecção de mudanças consiste nas seguintes etapas: (i) pré-processamento (Figura 4), onde as imagens são registradas e o MLME é empregado para produzir imagens de fração representando componentes adequadas a cena; (ii) análise dos dados (Figura 5), que consiste na produção das imagens diferença por subtração das correspondentes frações, (iii) estimação dos parâmetros da função densidade de probabilidade, (iv) cálculo dos graus de pertinência baseado numa lógica *fuzzy* para cada uma das classes, e (v) inserção de informações de contexto espacial, que neste caso será implementado por meio de conceitos derivados da relaxação probabilística.

Esta dissertação se propõe a investigar a detecção de mudanças empregando um subconjunto das componentes: aquele que melhor caracterize a ocorrência de alterações na cena em consideração. Em cenas naturais é frequente o emprego de três componentes: vegetação, solo e sombra/água. A proposta aqui investigada está baseada em duas componentes: vegetação e solo. Analisando os dados (Figura 6), pode-se constatar a existência de uma correlação negativa entre a distribuição das diferenças de vegetação e solo.

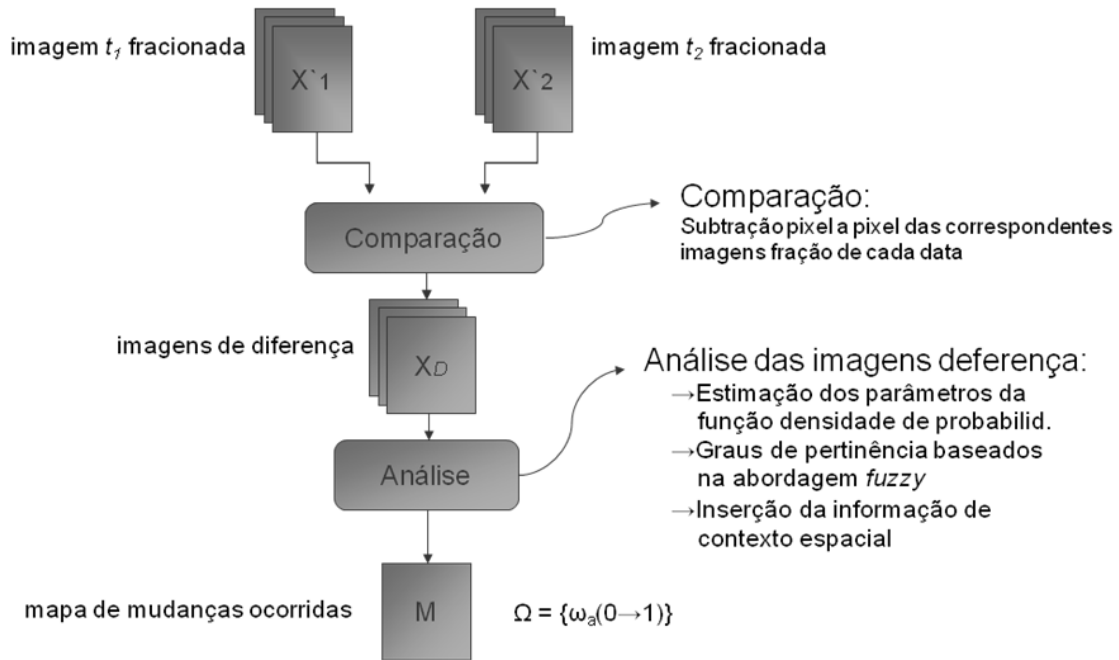
Essa correlação é explicada naturalmente pelo consequente aumento na fração de solo resultante da diminuição da fração vegetação. Da mesma forma, um incremento na componente vegetação (rebrotas) resulta em um decremento na componente solo<sup>2</sup>.



**Figura 4 - Esquema geral do pré-processamento: as imagens X1 e X2 são registradas, e após, fracionadas nas suas componentes pelo MLME, gerando as imagens X'1 e X'2 registradas e fracionadas.**

---

<sup>2</sup> Essa correlação é evidenciada apenas em estudos onde os principais alvos a serem considerados são vegetação e solo. Um problema envolvendo multiclasses possivelmente não apresentará a relação entre vegetação e solo da mesma forma evidenciada aqui.



**Figura 5 - Esquema geral de análise dos dados: as imagens dos dois períodos fracionadas são comparadas por subtração pixel a pixel gerando as imagens de diferença para cada fração; os parâmetros estatísticos que caracterizam as funções densidade de probabilidade são estimados e usados numa classificação Bayesiana que dá origem aos graus de pertinência da abordagem *fuzzy*; a última etapa consiste em aplicar informações de contexto espacial por conceitos de relaxação probabilística.**

### 3.2 Pré-processamento das imagens

Uma das vantagens apresentadas pela metodologia proposta nesta dissertação consiste em tornar desnecessária a etapa de normalização radiométrica das imagens multitemporais. Nas metodologias propostas na literatura, o processo de detecção de mudanças é realizado comparando diretamente dados multiespectrais obtidos em datas distintas (Hall *et al*, 1991). Nesta situação, a normalização radiométrica se faz necessária para colocar todas as imagens utilizadas dentro de um mesmo referencial radiométrico. A abordagem proposta nesta dissertação, ao empregar imagens fração na geração de imagens de diferença, dispensa a etapa de normalização radiométrica, pois o MLME é aplicado independentemente para cada data.

### 3.3 Registro espacial das imagens

O grau de processamento ordinário das imagens conta com um georeferenciamento baseado no modelo orbital. Evidentemente que, ao proceder a comparação pixel a pixel em imagens adquiridas em datas distintas, o processo de registro das imagens deve contar com um grau de exatidão muito superior àquele obtido normalmente pela simples referência do modelo orbital do satélite. Para tanto, um processo de registro imagem-imagem foi aplicado nas imagens multitemporais utilizadas. Tal processo baseia-se na escolha de uma imagem (nesse estudo optou-se por utilizar sempre a imagem da primeira data) que será usada como referência para posterior orientação da segunda imagem (segunda data). Sendo assim, esse método tem como único objetivo colocar as imagens em um mesmo referencial geométrico; nenhuma das imagens torna-se geocodificada ao final desse processo.

### 3.4 Geração das Imagens de Fração

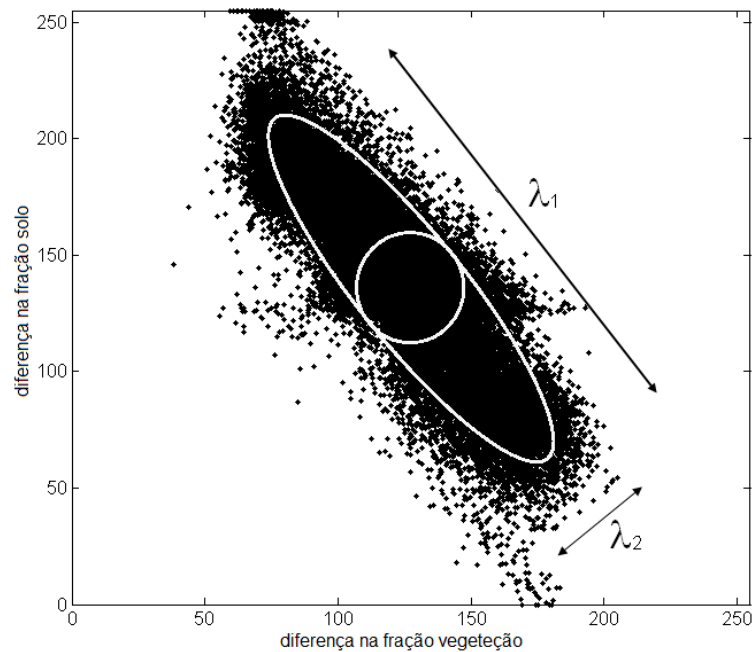
Como mencionado anteriormente, as imagens foram fracionadas em componentes de vegetação, solo e sombra/água a partir do MLME de acordo com as equações transcritas na seção 2.1. Pixels puros representando cada um dos *endmembers* escolhidos foram selecionados diretamente das imagens empregadas com base nas características espectrais de cada uma das três componentes da forma descrita a seguir. Para a componente vegetação, o pixel puro foi escolhido levando-se em conta os valores de índice de vegetação por diferença normalizada (NDVI) aliado à resposta espectral da banda corresponde ao infravermelho próximo. O pixel que apresentou o maior valor para o somatório daquelas duas grandezas foi definido como puro para a vegetação. Para a componente solo, o pixel escolhido foi aquele que apresentou o maior resultado do somatório dos valores registrados em todas as bandas. Para a sombra/água, o pixel puro escolhido foi aquele que apresentou o menor resultado do somatório dos valores digitais de todas as bandas. As regiões cobertas por nuvens foram descartadas neste processo. O algoritmo usado para o processamento em linguagem Matlab encontra-se no Apêndice da dissertação (algoritmos 1 e 2).



### 3.5 Estimação dos valores iniciais para o algoritmo EM

Conforme mencionado na seção 3.1, a proposta nesta dissertação consiste em detectar mudanças com base em imagens de diferença de frações empregando um sub-conjunto das componentes na cena em estudo, neste caso as componentes vegetação e solo. As variáveis aqui consideradas são portanto bi-dimensionais (diferenças na fração vegetação e na fração solo). A metodologia proposta requer portanto a estimação de funções densidade de probabilidade neste espaço bi-dimensional. Assumindo uma distribuição Normal bi-variada, o passo inicial requerido consiste na estimação dos parâmetros associados a esta distribuição (vetor de médias e matriz de covariância) e da probabilidade *a priori* associada às classes mudança e não-mudança. Nesta dissertação estas estimações são realizadas iterativamente por meio do algoritmo EM. Para se obter valores iniciais razoáveis para o algoritmo EM, as seguintes considerações são aqui propostas. A nuvem elipsoidal de pontos (Figura 6) ilustrando a correlação negativa entre as duas variáveis, deveria idealmente se apresentar sob uma forma linear (sem dispersão ortogonal a linha). Devido a inevitável ocorrência de ruídos e também de pequenas variações não significativas, a relação entre as duas variáveis acaba apresentando uma dispersão em torno da linha ideal (Figura 6). Desta forma, o conjunto das amostras empregado para uma representação inicial para a classe não-mudança pode ser assumido como aquele formado pelas amostras centradas em torno da origem (alteração zero), com uma dispersão circular. Assume-se aqui que esta dispersão isotrópica é causada pela presença de ruídos aleatórios, além de pequenas mudanças não significativas. A dispersão neste conjunto de amostras pode então ser estimada pelo segundo auto-valor do conjunto total das variáveis (Figura 6). Neste caso, a estimativa inicial para a matriz de covariância associada a classe não-mudança consiste em uma matriz diagonal (covariâncias nulas) e variâncias iguais ao segundo autovalor estimado para o conjunto total das variáveis. Os parâmetros para a classe mudança (vetor de médias e matriz de covariância) são aqui estimados a partir do conjunto total das amostras disponíveis (Figura 6). O objetivo em obter-se valores iniciais para os parâmetros para ambas as classes próximos aos valores corretos reside em reduzir o número de iterações no algoritmo EM e conseqüentemente o tempo de processamento. De qualquer forma, o processo iterativo converge uma vez que o algoritmo EM é um algoritmo robusto convergindo para um mesmo valor final independentemente das condições iniciais impostas (Dempster *et al.* 1977).

Como geralmente o número de pixels apresentando pequena mudança ou mudança nula é muito maior do que o número de pixels apresentando sinais claros de mudança, os valores iniciais das probabilidades *a priori* podem ser definidos inicialmente como  $P(\omega_c)=0.1$  e  $P(\omega_{nc})=0.9$ . Dependendo de cada caso em particular, esses valores podem variar empiricamente.



**Figura 6 - Gráfico de espalhamento dos dados da imagem de diferenças: o primeiro autovalor ( $\lambda_1$ ) é a variância estimada provisoriamente para a classe mudança ( $\sigma_1^2$ ) enquanto o segundo autovalor ( $\lambda_2$ ) é a variância estimada também provisoriamente para a classe não mudança ( $\sigma_2^2$ ).**

### 3.6 Aplicação do algoritmo EM

Nesse ponto o problema consiste em estimar de maneira mais precisa os parâmetros estatísticos para as distribuições de probabilidade e para as probabilidades *a priori* das classes mudança e não-mudança (vetor de médias, matriz de covariância e probabilidade *a priori*). Como os dados são assumidos como distribuídos normalmente, o algoritmo EM pode ser usado para esse fim (Duda *et al.* 2001). As estimações de máxima verossimilhança geradas por esse algoritmo podem ser calculadas iterativamente a partir de duas etapas que se alternam de iteração para iteração (Duda *et al.* 2001):

Etapa 1:

$$\begin{aligned}\hat{P}(\omega_i | \mathbf{X}_k, \hat{\boldsymbol{\theta}}) &= \frac{p(\mathbf{X}_k | \omega_i, \hat{\boldsymbol{\theta}}_i) P(\omega_i)}{\sum_{j=1}^c p(\mathbf{X}_k | \omega_j, \hat{\boldsymbol{\theta}}_j) P(\omega_j)} \\ &= \frac{|\hat{\boldsymbol{\Sigma}}_i|^{-1/2} \exp\left[-\frac{1}{2}(\mathbf{X}_k - \hat{\boldsymbol{\mu}}_i)' \hat{\boldsymbol{\Sigma}}_i^{-1} (\mathbf{X}_k - \hat{\boldsymbol{\mu}}_i)\right] \hat{P}(\omega_i)}{\sum_{j=1}^c |\boldsymbol{\Sigma}_j|^{-1/2} \exp\left[-\frac{1}{2}(\mathbf{X}_k - \boldsymbol{\mu}_j)' \boldsymbol{\Sigma}_j^{-1} (\mathbf{X}_k - \boldsymbol{\mu}_j)\right] P(\omega_j)}\end{aligned}\quad (3.1)$$

Etapa 2:

$$\hat{P}(\omega_i) = \frac{1}{n} \sum_{k=1}^n \hat{P}(\omega_i | \mathbf{X}_k, \hat{\boldsymbol{\theta}}) \quad (3.2)$$

$$\hat{\boldsymbol{\mu}}_i = \frac{\sum_{k=1}^n \hat{P}(\omega_i | \mathbf{X}_k, \hat{\boldsymbol{\theta}}) \mathbf{X}_k}{\sum_{k=1}^n \hat{P}(\omega_i | \mathbf{X}_k, \hat{\boldsymbol{\theta}})} \quad (3.3)$$

$$\hat{\boldsymbol{\Sigma}}_i = \frac{\sum_{k=1}^n \hat{P}(\omega_i | \mathbf{X}_k, \hat{\boldsymbol{\theta}}) (\mathbf{X}_k - \hat{\boldsymbol{\mu}}_i)(\mathbf{X}_k - \hat{\boldsymbol{\mu}}_i)'}{\sum_{k=1}^n \hat{P}(\omega_i | \mathbf{X}_k, \hat{\boldsymbol{\theta}})} \quad (3.4)$$

onde o vetor  $\boldsymbol{\theta}_i$  representa os parâmetros na classe  $\omega_i$  e  $c$  é o número de classes presentes na mistura (no caso de detecção de mudanças  $c=2$ ).

A etapa 1, chamada de *expectation*, calcula uma expectativa do logaritmo da verossimilhança para as estimações em questão e a etapa 2, chamada de *maximization*, calcula os parâmetros que maximizam as expectativas geradas pelo logaritmo da verossimilhança encontrado na etapa 1 (Duda *et al.* 2001).

Começando com as estimações iniciais de  $\boldsymbol{\mu}_i$ ,  $\boldsymbol{\Sigma}_i$  e  $P(\omega_i)$ , o algoritmo EM vai atualizando estas estimações até a convergência. Uma vez obtida a convergência, os valores estimados podem ser implementados nas funções de decisão Bayesianas (2.5) para estimar os graus de pertinência às classes mudança e não-mudança. O algoritmo usado para o processamento em linguagem Matlab encontra-se no Apêndice (algoritmo 3).

### 3.7 Função de decisão Bayesiana para o cálculo dos graus de pertinência

A partir da equação (2.5), valores para as funções de decisão  $G_n$  podem ser calculados. Para o caso de duas classes ( $\omega_1$  e  $\omega_2$ ) a regra Bayesiana de decisão<sup>3</sup> é dada por:

$$\begin{cases} x \in \omega_1, G_1(x) > G_2(x) \\ x \in \omega_2, G_1(x) < G_2(x) \end{cases} \quad (3.5)$$

Em uma abordagem *fuzzy*, a equação (2.5) pode ser empregada para estimar o grau de pertinência de cada pixel à cada uma das duas classes em questão:

**grau de pertinência à classe 1:**

$$\in classe(1) \rightarrow w_1 = \frac{G_1(x)}{G_1(x) + G_2(x)} \quad (3.6)$$

**grau de pertinência à classe 2:**

$$\in classe(2) \rightarrow w_2 = \frac{G_2(x)}{G_1(x) + G_2(x)} \quad (3.7)$$

onde  $G_1(x)$  e  $G_2(x)$  são as funções de decisão Bayesianas para as classes mudança e não-mudança.

É importante enfatizar que esta abordagem não estima um valor porcentual de mudança nem tem nenhum significado estatístico caracterizável. Apenas atribui um valor de pertinência baseado nos valores calculados para as funções de decisão. Talvez o significado mais razoável fosse dizer que esse valor estima o grau de confiança com que um pixel pode ser rotulado em uma determinada classe, em contraposição a classificação do tipo “duro”

---

<sup>3</sup> Nota-se que a regra de decisão Bayesiana não está completamente definida para  $x$ . Estaria, caso uma das equações contasse, além da desigualdade, com uma igualdade. A igualdade pode ser adicionada em qualquer uma das regras de decisão Bayesiana sem maior prejuízo para o resultado. Na verdade, para duas classes e para duas dimensões de dados (diferença de vegetação e solo), os valores idênticos para as duas funções de decisão devem existir apenas para uma curva formada pela intersecção entre as duas gaussianas e dificilmente os valores de algum item (no caso pixel) a ser classificado corresponderão a um ponto nessa região.

(*hard*), na qual cada pixel é integralmente rotulado em uma determinada classe. O algoritmo usado para o processamento em linguagem Matlab encontra-se no Apêndice (algoritmo 4).

### 3.8 Inserção de informações de contexto espacial

Nas seções anteriores, foi abordado o problema da estimação dos graus de pertinência para as classes mudança e não-mudança aplicando a função Bayesiana de decisão para as diferenças entre as imagens de fração produzidas a partir de imagens coletadas em duas datas distintas. Nessa seção é proposta uma maneira de refinar estas estimações por meio da incorporação de informações de contexto espacial.

Métodos para implementar contexto espacial em classificação de imagens têm sido discutidos por diferentes autores (Therrien, 1989). As metodologias mais comumente aplicadas para implementar tais informações são (i) relaxação probabilística e (ii) métodos de Markov. Nesse estudo é proposta uma aplicação da relaxação probabilística para atualizar os graus de pertinência dos pixels da imagem para as classes mudança e não-mudança. O método de relaxação probabilística foi investigado por Di Zenzo *et al.* (1986) para aumentar a acurácia de imagens temáticas. Segundo essa abordagem, a probabilidade  $p(i,h)$  de um pixel na posição  $i$  pertencer à classe  $\omega_h$  ( $i \in \omega_h$ ) pode ser atualizada em um processo iterativo da seguinte maneira:

$$p^{t+1}(i, h) = p^t(i, h) \frac{1}{L} \left( 1 + (1/8) \sum_{j=1}^n \sum_{k=1}^c r(i, j, h, k) p^t(j, k) \right) \quad (3.8)$$

onde  $L$  corresponde a um fator de normalização dado por:

$$L = \sum_{h=1}^c \left( 1 + (1/8) \sum_{j=1}^n \sum_{k=1}^c r(i, j, h, k) p^t(j, k) \right) \quad (3.9)$$

Nas equações (3.8 e 3.9),  $c$  representa o número de classes na imagem temática,  $n$  o número de pixels que compõe a vizinhança,  $t$  a iteração atual do processo de relaxação,  $p(j,k)$

a probabilidade de um pixel vizinho na posição  $j$  pertencer à classe  $\omega_k$  ( $j \in \omega_k$ ),  $r(i,j,h,k)$  o coeficiente de compatibilidade que estima a probabilidade de um pixel na posição  $i$  pertencer à classe  $\omega_h$  ( $i \in \omega_h$ ) e seu vizinho na posição  $j$  pertencer à classe  $\omega_k$  ( $j \in \omega_k$ ). O coeficiente de compatibilidade pode ser estimado da seguinte maneira segundo Di Zenzo *et al.* (1986):

$$r(j,h,k) = E \left[ \ln \frac{p(i \in h, j \in k)}{p(i \in h) p(j \in k)} \right] \quad (3.10)$$

Um outro método para calcular o coeficiente de compatibilidade foi proposto por Hsiao e Sawchuk (1989):

$$r(i,j,h,k) = \frac{1}{5} \ln \left( \frac{E[p(i \in h, j \in k)]}{E[p(i \in h)] E[p(j \in k)]} \right) \quad (3.11)$$

$$V^{t+1}(i,h) = V^t(i,h) \frac{1}{L} \left( 1 + (1/8) \sum_{j=1}^n \sum_{k=1}^c r(i,j,h,k) V^t(j,k) \right) \quad (3.12)$$

onde  $V^t(i,h)$  representa o grau de pertinência do pixel na posição central  $i$  com respeito a classe  $\omega_h$ , e  $L$  o fator de normalização:

$$L = \sum_{h=1}^c \left( 1 + (1/8) \sum_{j=1}^n \sum_{k=1}^c r(i,j,h,k) V^t(j,k) \right) \quad (3.13)$$

Neste caso, o número de classes ( $c$ ) é igual a dois (mudança, não-mudança). Também, para a vizinhança são considerados os oito vizinhos imediatamente próximos<sup>4</sup> ( $n=8$ ) como descrito na Figura 7.

Como os graus de pertinência estão contidos no intervalo contínuo  $[0, 1]$ , se propõe implementar um método similar para atualizar os graus de pertinência às classes mudança e não-mudança baseados nas informações de contexto espacial. No presente caso,

<sup>4</sup> Também chamado de vizinhança de segunda ordem do pixel.

diferentemente do que foi investigado em Di Zenzo *et al.* (1986), onde o processo de relaxação é probabilística porque atualiza os valores das probabilidades para as classes, aqui o processo de relaxação deve ser aplicado aos graus de pertinência. Sendo assim, a designação mais apropriada para descrever o processo adaptado é simplesmente o termo relaxação.

A forma modificada para a equação (3.11) proposta nessa dissertação para estimar os coeficientes de compatibilidade é a seguinte:

$$r(i, j, h, k) = \frac{1}{5} \ln \left( \frac{N(i, j, h, k) / N}{\left( \sum_{h=1}^c N(i, j, h, k) / N \right) \left( \sum_{k=1}^c N(i, j, h, k) / N \right)} \right) \quad (3.14)$$

onde  $N(i, j, h, k)$  representa a soma (em toda a imagem) dos graus de pertinência à classe  $\omega_h$  do pixel central na posição  $i$  e o grau de pertinência à classe  $\omega_k$  do seu vizinho na posição  $j$ , e  $N$  o número total de pixels na imagem. O termo  $N(i, j, h, k) / N$  estima o valor médio para os graus de pertinência de um pixel na posição  $i$  para a classe  $\omega_h$  e seu vizinho na posição  $j$  à classe  $\omega_k$ . Os termos  $\left( \sum_{h=1}^c N(i, j, h, k) / N \right)$  e  $\left( \sum_{k=1}^c N(i, j, h, k) / N \right)$  estimam o valor médio para o grau de pertinência à classe  $\omega_h$  para o pixel na posição central e  $\omega_k$  para seu vizinho  $j$ , respectivamente. Em termos probabilísticos, o valor encontrado em (3.14) estima a probabilidade de ocorrência dos dois eventos simultaneamente (pixel central  $i \in \omega_h$  e seu vizinho na posição  $j \in \omega_k$ ). Os dois fatores no denominador estimam as duas distribuições marginais. Adicionalmente, foi assumida invariância espacial para o coeficiente de compatibilidade, i.e., a equação (3.14) não depende de  $i$ . Neste caso, em termos computacionais, os valores de  $r$  podem ser convenientemente armazenados em uma matriz  $r(8,2,2)$ . O algoritmo usado para o processamento em linguagem Matlab encontra-se no Apêndice (algoritmo 5).

$j_1$	$j_2$	$j_3$
$j_8$	$i$	$j_4$
$j_7$	$j_6$	$j_5$

**Figura 7 - Vizinhança considerada para o contexto espacial.**

A convergência do processo é alcançada quando a diferença entre os pixels correspondentes das imagens produzidas por duas iterações consecutivas não for consideravelmente alta. A imagem resultante é um mapa de mudanças indicando através de graus de pertinência as mudanças ocorridas na região estudada entre as duas datas consideradas.



## 4 TESTES E EXPERIMENTOS

### 4.1 Introdução

Nesta seção são apresentados e discutidos os experimentos realizados para fins de teste da metodologia proposta. As rotinas computacionais necessárias para os experimentos foram implementadas em ambiente Matlab e encontram-se Anexadas à dissertação. São apresentados três experimentos, um envolvendo uma imagem sintética e dois empregando dados reais. O experimento com dados sintéticos teve como objetivo testar o processo com base em dados de referência de extrema confiança, ou seja, um par de imagens onde se tem um conhecimento completo das alterações existentes. Os testes foram realizados confrontando quantitativamente as alterações sintéticas introduzidas com os resultados gerados pela metodologia proposta. Num segundo momento, um teste empregando imagens reais foi executado utilizando uma imagem *Landsat 5-TM* empregada no primeiro experimento como imagem data 1 (Outubro de 1991) e uma segunda imagem *Landsat 5-TM* da mesma região mas de Novembro de 1994 (data 2). Finalmente, duas imagens CBERS-2B tomadas em Abril e Junho/2009 da região do Pantanal Brasileiro foram utilizadas num experimento para detectar queimadas ocorrentes entre a aquisição das imagens. A exposição em detalhe da metodologia proposta é mostrada apenas para os experimentos com as imagens *Landsat 5-TM*. No experimento realizado com as imagens CBERS-2B, para detectar queimadas no Pantanal, são mostrados apenas os resultados finais. Um breve comentário sobre o custo computacional do processo é feito ao final deste capítulo.

### 4.2 Dados imagem utilizados

Imagens do satélite *Landsat 5*, sensor *Thematic Mapper* (TM) e do satélite CBERS-2B, sensor CCD, foram utilizadas nos experimentos realizados para desenvolver e testar a metodologia empregada no estudo.

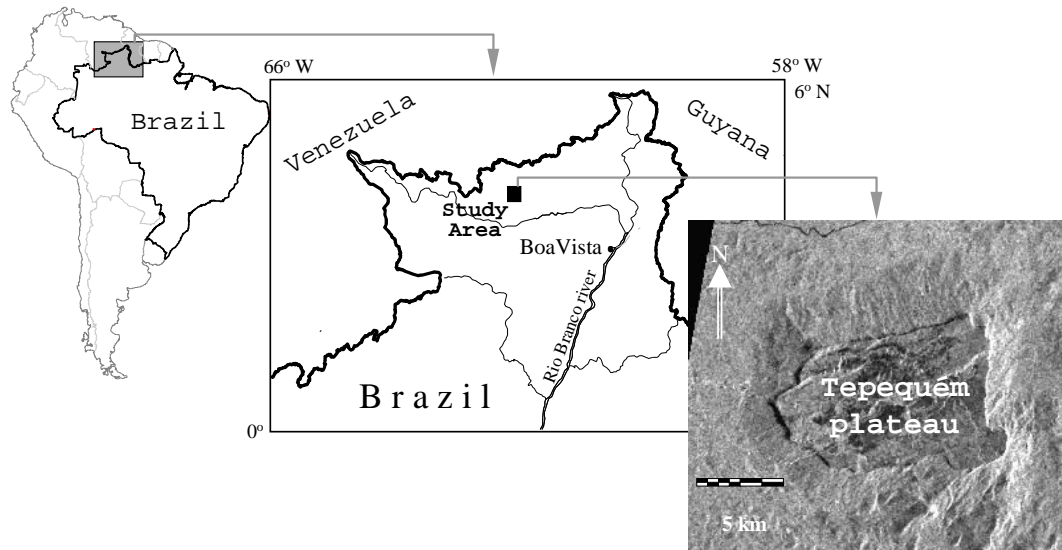
O sistema *Landsat 5*, assim como suas versões anteriores e posteriores, segue uma órbita *quasi-polar* e heliosíncrona, numa altitude de 710 km acima da superfície terrestre e

com resolução temporal de 16 dias. Possui sete bandas espectrais, sendo três na região do visível (canal 1: 0,45-0,52; canal 2: 0,52-0,60; canal 3: 0,63-0,69), uma no infravermelho próximo (canal 4: 0,76-0,90), duas na região do infravermelho médio (canal 5: 1,55-1,75; canal 7: 2,08-2,35) e uma na região do infravermelho termal (10,40-12,50). Todos os canais possuem resolução espacial de 30 m, com exceção do canal termal, que corresponde a 120 m. (NASA, 2009)

O sistema CBERS nasceu de uma parceria entre China e Brasil. Sua terceira versão, o CBERS-2B está a uma altura média de 778 km e possui uma resolução temporal de 26 dias. O sensor CCD, presente no sistema desde sua primeira versão, possui cinco bandas [0,51 - 0,73  $\mu\text{m}$  (pancromática); 0,45 - 0,52  $\mu\text{m}$  (azul); 0,52 - 0,59  $\mu\text{m}$  (verde); 0,63 - 0,69  $\mu\text{m}$  (vermelho); 0,77 - 0,89  $\mu\text{m}$  (infravermelho próximo)] todas com resolução espacial de 20 m. (INPE, 2009)

### 4.3 Área de estudo selecionada

A área de estudo foi selecionada com o objetivo de acompanhar a seqüência de estudos sobre detecção de mudanças que vêm sendo desenvolvidos pela linha de pesquisa em reconhecimento de padrões do programa de pós-graduação em sensoriamento remoto da UFRGS. A metodologia proposta foi testada em imagens cobrindo uma área localizada no estado de Roraima, norte do Brasil, definida pelas coordenadas 61°37'– 61°49'E e 3°40'- 3°52'N. A razão desta escolha deve-se a experiência adquirida em trabalhos anteriores (Haertel *et al.* 2004) e ao conhecimento de campo da mesma. Esta área é caracterizada por duas planícies distintas, uma localizada a uma altitude média de 200 m e outra localizada numa alta elevação formando um platô: o Platô do Tepequém. Uma floresta densa cobre a região de baixa elevação, enquanto a região do platô é dominada por cerrado. A Figura 8 ilustra a localização da região estudada.




**Figura 8 - Área de estudo.**

*Fonte: Haertel et al., 2004.*

#### 4.4 Produção das imagens fração

Com base no conhecimento prévio da área, selecionou-se as classes vegetação, solo e sombra/água como componentes na cena, conforme descrito na seção 3.4. Exemplos destas três componentes estão ilustrados na Figura 9.



**Figura 9 - Pixels usados como *endmembers* de (a) vegetação, (b) solo e (c) sombra/água para o processo de fracionamento da imagem *Landsat* de 1991.**


Para o fracionamento, foram utilizadas as seis bandas reflectivas disponibilizadas pelo sistema sensor *Landsat 5-TM*. A partir do MLME, três imagens de fração foram produzidas<sup>5</sup>. A Figura 10 mostra as imagens fração estimadas para as componentes vegetação, solo e sombra/água.

Esta fase do processamento foi considerada a mais custosa em termos computacionais. Com aproximadamente 90% do tempo total (dependendo do número de iterações do processo estimação dos parâmetros das distribuições e do processo de relaxação), a produção das imagens fração deve ser analisada de forma a reduzir o seu tempo de processamento com processamentos paralelos, já que essa função pode ser paralelizável do ponto de vista do processamento computacional. A divisão da imagem em blocos<sup>6</sup> e posterior reagrupamento foi experimentada e apresentou razoável melhora no tempo de processamento. O referente algoritmo é mostrado nos anexos da dissertação.

---

<sup>5</sup> Como o número de bandas utilizadas supera o número de imagens fração produzidas, existirá mais de uma solução para o problema. O método dos mínimos quadrados foi utilizado para produzir o melhor ajustamento numérico.

<sup>6</sup> Os números de blocos testados foram diversos, mas o que aparece no algoritmo do apêndice e usado para os experimentos da dissertação é 10.000, sendo esse valor definido sem base em nenhuma razão teórica ou prática.



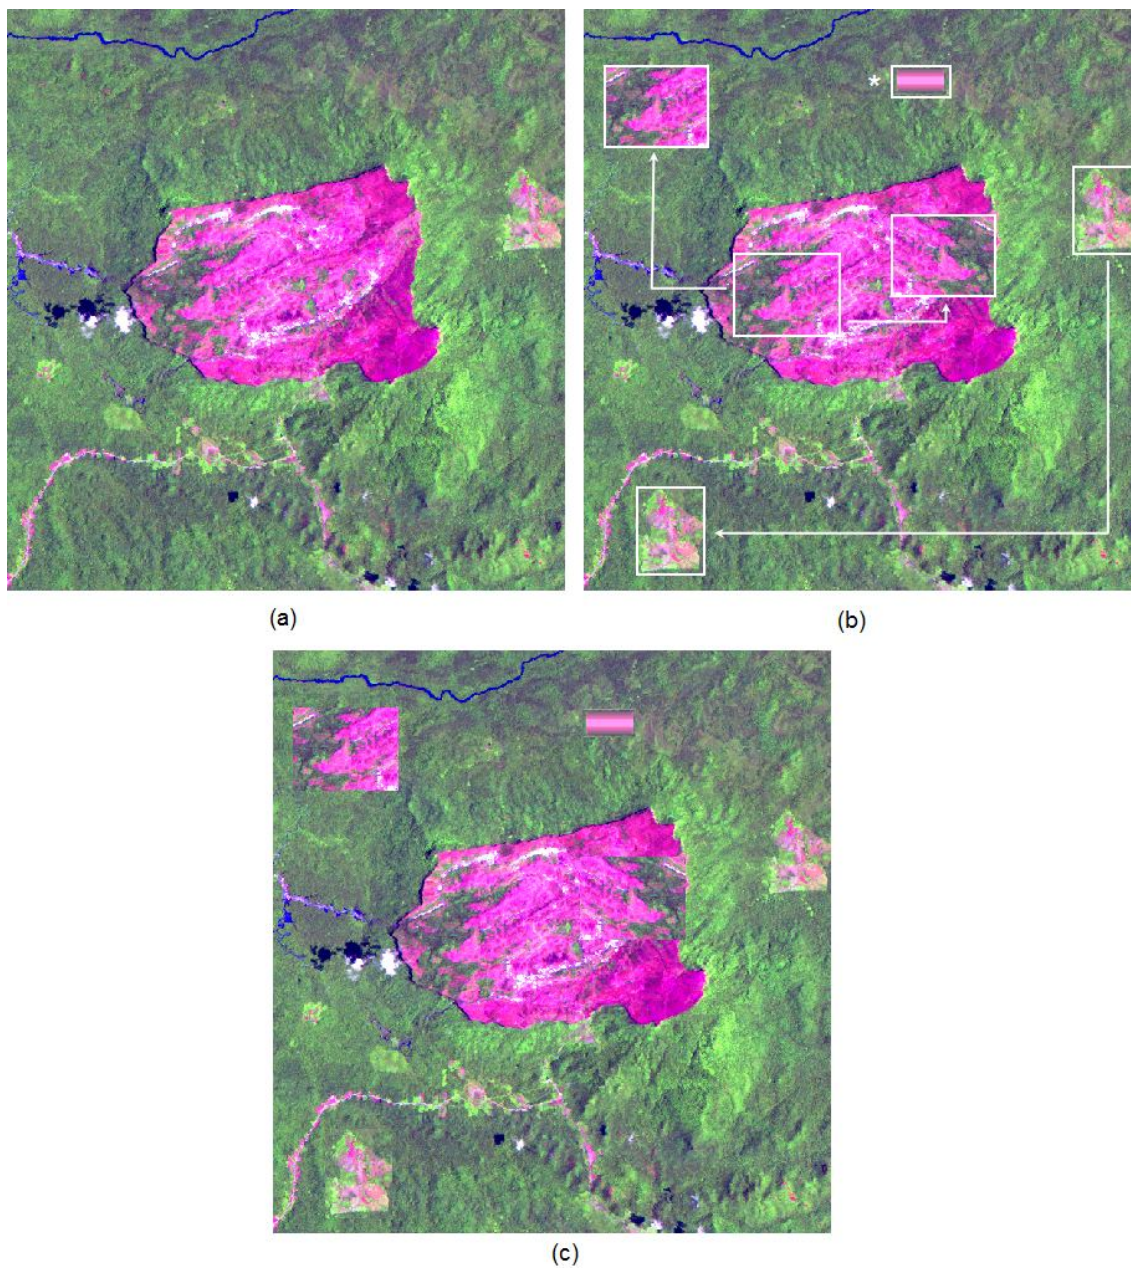
**Figura 10 -** Imagens de fração geradas pelo MLME a partir das bandas 1-5 e 7 da imagem *Landsat 5-TM* de 1991 para (a) vegetação, (b) solo e (c) sombra. Variação contínua de preto (0% da componente) a branco (100% da componente).

#### 4.5 Produção da imagem sintética

Conforme mencionado anteriormente, no primeiro experimento foi feito uso de uma imagem sintética. A maior utilidade nesta abordagem reside na possibilidade do

conhecimento completo e exato das alterações ocorridas, inclusive em termos quantitativos (grau de alteração). Uma segunda vantagem consiste na eliminação dos erros residuais resultantes do processo de registro de duas imagens. A imagem sintética foi produzida por meio da inclusão de alterações controladas na imagem Landsat-TM empregada como imagem da data 1.

Na geração da imagem sintética foram aplicadas alterações bem definidas, visando simular a ação de fatores modificadores naturais do terreno. As mudanças aplicadas sinteticamente correspondem ao simples transporte de algumas áreas para outras regiões da imagem. A Figura 11a ilustra uma composição em falsa cor 5(R) 4(G) 3(B) da imagem *Landsat* de 1991. A Figura 11b apresenta um diagrama com as alterações introduzidas na imagem original. O retângulo marcado com um asterisco na porção superior da figura indica uma simulação para o desmatamento da área anteriormente coberta por vegetação: diretamente nos valores das frações de solo e vegetação, os contadores digitais foram incrementados para a fração solo e decrementados para a fração vegetação, sendo que a intensidade das alterações foi menor nas bordas, aumentando gradualmente em direção ao interior da feição destacada. Idênticos valores subtraídos da fração de vegetação foram adicionados a fração de solo para o mesmo pixel, não alterando, assim, o valor 100% exibido pelo somatório das frações em cada pixel. O correspondente resultado sintético gerado pelas mudanças artificiais inseridas na imagem original é mostrado na Figura 11c.

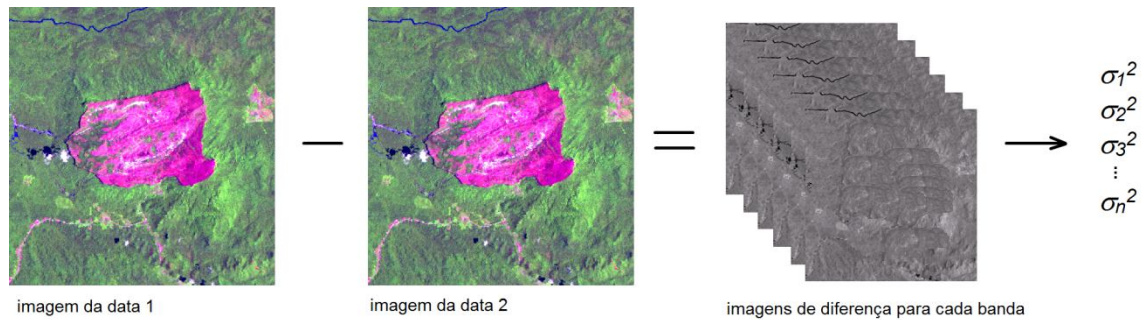


**Figura 11 - Recorte da cena *Landsat 5-TM* de Outubro de 1991 utilizada: (a) composição em falsa cor 5(R) 4(G) 3(B) da imagem correspondente à primeira data, (b) croqui explicativo das mudanças inseridas sinteticamente na imagem (a), imagem usada como correspondente da segunda data, resultante das alterações sintéticas aplicadas e do ruído aleatório com distribuição normal aplicado (c).**

Com o objetivo de tornar o experimento com a imagem sintética mais próximo do real, um ruído espacial aleatório com distribuição normal foi aplicado em toda a imagem sintética simulando os efeitos aleatórios causados pelos fenômenos naturais anteriormente descritos.

Dessa forma, uma classe não-mudança de origem sintética aparecerá na mistura de densidades de probabilidade apresentada pela imagem de diferenças, possibilitando então a simulação realística da cena e a aplicação do algoritmo EM para identificar os parâmetros das duas distribuições presentes na mistura.

Uma questão que surge nessa etapa é de que maneira estimar a variância do ruído. O método proposto nesta dissertação para a produção do ruído consiste em usar duas imagens da mesma região, mas com baixa defasagem temporal, assumindo que não existam mudanças efetivas ocorridas. Assim, ao efetuar a subtração das imagens, banda por banda, as imagens diferença resultantes devem produzir uma estimativa da variância de cada banda ( $\sigma_n^2$ ) para a classe não-mudança, que poderá subseqüentemente ser aplicada na geração da imagem sintética. Para manter o controle total do processo, o ruído espacial foi aplicado na imagem antes de efetuadas as alterações sintéticas. Um diagrama esquemático exemplifica o processo (Figura 12).



**Figura 12 - Método utilizado para definir a variância da classe não mudança, valor que será utilizado para produzir o ruído aleatório a ser aplicado na imagem sintética.**

#### 4.6 Produção das imagens diferença

As imagens diferença foram geradas pela subtração pixel a pixel das correspondentes frações de vegetação e solo para as duas datas consideradas (nesse caso a imagem sintética foi considerada como sendo a imagem da segunda data). Deve-se observar aqui que, conforme mencionado no Capítulo 3, somente as frações de vegetação e de solo são empregadas na detecção de mudanças. Entende-se que as informações contidas na componente sombra não




apresentam uma contribuição significativa na detecção de alterações. Uma razão adicional para este procedimento reside na variação anual no ângulo de elevação solar, em uma mesma região e na mesma hora do dia, alterando a intensidade da sombra. Esta variação não serve portanto para indicar a ocorrência de alterações na cobertura do solo. A Figura 13 ilustra as imagens diferença produzidas para as frações de vegetação e solo.

Ainda com relação a produção das imagens de diferenças, e com o objetivo de facilitar a implementação da metodologia proposta, a seguinte transformação foi aplicada aos dados. As diferenças apresentadas para a fração de vegetação (Figura 13a) e solo (Figura 13b) estão no formato byte, ou seja, com variação de 0 a 255 no valor do pixel. Ao efetuar a subtração de duas imagens no formato byte, o número digital caracterizando as alterações em cada pixel estará contido no intervalo  $[-255, 255]$ . Deve-se observar, entretanto, que a imagem no formato possível de ser visualizada em tela não pode conter valores negativos, e, portanto, o intervalo para a variação deve ser re-escalonado para o intervalo  $[0, 255]$ . Essa transformação implica numa translação dos referenciais que indicam o grau de alteração ocorrida. O valor que anteriormente simbolizava uma ausência de mudança (zero) na imagem de diferença, agora passa a ser 127.5. Uma total mudança negativa de vegetação, ou seja, um pixel que apresentou um valor de -255 na subtração (vegetação nula onde antes existia domínio dessa componente), passa a ser simbolizado por zero no formato byte. Da mesma forma, uma total mudança positiva na componente vegetação continua sendo representado pelo mesmo valor (255). Isso explica o aspecto acinzentado das Figura 13a e 13b: as regiões que não sofreram mudanças efetivas apresentam valores próximos a 127.5, que corresponde a um nível de cinza intermediário<sup>7</sup>.


---

<sup>7</sup> O cinza predominante não é absolutamente monocromático pelo fato de existir o ruído aleatório introduzido na imagem sintética.



**Figura 13 - Imagem de diferença produzida por subtração para o primeiro experimento no formato byte (0-255) para a fração de (a) vegetação e (b) solo.**

Os histogramas de cada uma das duas variáveis (diferença na fração vegetação e diferença na fração solo) são mostrados na Figura 14. Ambos os histogramas sugerem distribuições Normais univariadas tanto para as diferenças na fração vegetação quanto nas diferenças na fração solo. Este resultado é razoável pois ambas as variáveis representam eventos naturais e são, portanto, o resultado da soma de várias outras variáveis aleatórias, fato este que tende a resultar em uma distribuição Normal (teorema do Limite Central).




**Figura 14 - Histogramas da imagem de diferenças: (a) diferença entre as frações de vegetação e (b) diferenças entre as frações de solo.**

## 4.7 Resultados relativos ao experimento realizado com dados sintéticos

### 4.7.1 Imagem de referência


Par fins de uma avaliação quantitativa deste experimento, torna-se necessário dispor de dados de referência. Em situações normais, estes dados são conhecidos como “verdade terrestre” e são utilizados tanto para fins de treinamento do classificador quanto para fins de teste dos resultados (métodos da re-substituição, *holdout*, *leave-one-out*). No presente experimento, onde são utilizados dados sintéticos, os dados de referencia para a avaliação da metodologia consistem em uma imagem contendo as alterações sinteticamente produzidas. Neste caso, portanto, a referência consiste em duas imagens, uma contendo as alterações introduzidas na variável diferença na fração de vegetação e uma segunda com as mudanças na variável diferença na fração solo. As duas referências foram combinadas em uma única somando-se os valores absolutos das duas e dividindo-se o valor resultante por 2, deixando-a novamente no formato byte (0-255).

A Figura 15 ilustra o procedimento.



**Figura 15 - Processo de obtenção da imagem de mudanças usada como referência para o primeiro experimento unindo diferenças nas frações de vegetação e solo: os valores absolutos das imagens de referência para as duas frações são somados pixel a pixel e o resultado é dividido por 2 para manter o resultado final no formato byte (0-255).**

A imagem resultante corresponde aos valores das mudanças que foram introduzidas à primeira imagem conjuntamente nas frações de vegetação e solo (Figura 16).



**Figura 16 - Imagens de referência para alterações sintéticas aplicadas no formato byte e em valores absolutos (0-255). Na figura a fração de vegetação foi somada com a fração de solo e o produto dividido por dois, de modo que o resultado fique no intervalo 0-255. O grau das alterações inseridas varia continuamente de branco (sem alteração inserida) para preto (valor máximo de alteração sintética inserida na imagem).**

#### 4.7.2 Estimação dos parâmetros das distribuições e das probabilidades *a priori* das classes mudança e não-mudança.

As imagens correspondentes às duas datas foram subtraídas pixel a pixel nas correspondentes frações de vegetação e solo dando origem a imagem de diferenças conforme descrito na seção 4.6. Os parâmetros estatísticos das distribuições de probabilidade envolvidas na mistura de densidades foram estimados da maneira descrita na seção 3.6. Para a imagem de diferenças do primeiro experimento (Figura 13), os parâmetros estatísticos utilizados como entrada para o algoritmo EM foram determinados conforme descrito na seção 3.5. Os autovetores e os correspondentes autovalores para as diferenças nas frações vegetação e solo foram estimados aplicando a transformação de Karhunen-Loeve. Os resultados obtidos para a matriz de autovetores ( $\mathbf{V}$ ) e correspondente matriz de autovalores ( $\mathbf{D}$ ) são:

$$\mathbf{V} = \begin{bmatrix} -0.42 & -0.91 \\ -0.91 & 0.42 \end{bmatrix} \quad \mathbf{D} = \begin{bmatrix} 21.5 & 0 \\ 0 & 57.4 \end{bmatrix}$$

Seguindo o método proposto na seção 3.5, os valores iniciais para os parâmetros das duas classes foram definidos como mostrado abaixo:

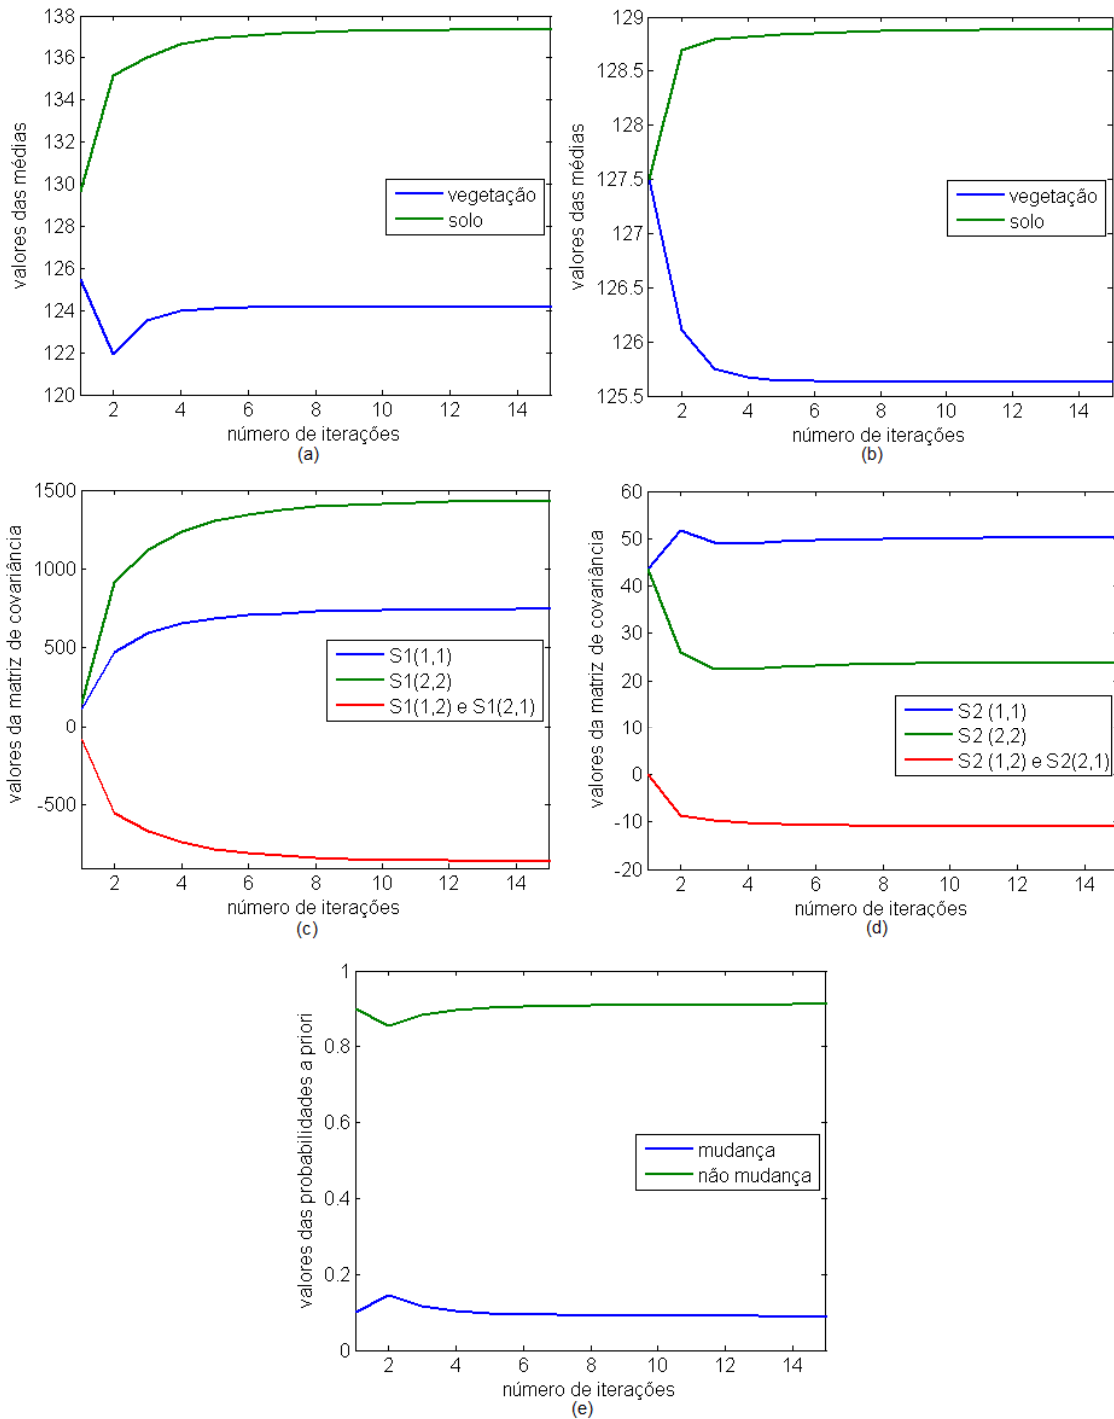
$$\boldsymbol{\mu}_c = \begin{bmatrix} 125.7 \\ 128.9 \end{bmatrix} \quad \boldsymbol{\Sigma}_c = \begin{bmatrix} 51.2 & -13.6 \\ -13.6 & 27.7 \end{bmatrix} \quad \boldsymbol{\mu}_{nc} = \begin{bmatrix} 127.5 \\ 127.5 \end{bmatrix} \quad \boldsymbol{\Sigma}_{nc} = \begin{bmatrix} 21.5 & 0 \\ 0 & 21.5 \end{bmatrix}$$

onde  $\boldsymbol{\mu}_c$  é o vetor de médias para a classe mudança,  $\boldsymbol{\mu}_{nc}$  é vetor de médias para a classe não mudança,  $\boldsymbol{\Sigma}_c$  é a matriz de covariâncias para a classe mudança e  $\boldsymbol{\Sigma}_{nc}$  é a matriz de covariâncias para a classe não-mudança. Os valores iniciais para as probabilidades *a priori* foram arbitrados como  $P(\omega_c)=0.1$  e  $P(\omega_{nc})=0.9$  (ver seção 3.5), onde  $\omega_c$  e  $\omega_{nc}$  correspondem a classe mudança e não-mudança respectivamente.

A partir das equações (3.1)-(3.4) o algoritmo EM é processado e tende a convergir da maneira exposta na seção 3.6. A convergência dos valores é geralmente alcançada com um número pequeno de iterações (Figura 17). Utilizou-se como critério de convergência um limiar considerando a diferença dos valores na iteração atual para a iteração imediatamente anterior. O progresso do algoritmo pode ser acompanhado observando-se as curvas da Figura 17. Para o presente experimento, a convergência foi obtida com 10 iterações apresentado os seguintes valores para o vetor de médias, a matriz de covariâncias e as probabilidades *a priori*:

$$\boldsymbol{\mu}_c = \begin{bmatrix} 124.1 \\ 137.3 \end{bmatrix}; \quad \boldsymbol{\Sigma}_c = \begin{bmatrix} 744.6 & -856.3 \\ -856.3 & 1430 \end{bmatrix}; \quad \boldsymbol{\mu}_{nc} = \begin{bmatrix} 125.6 \\ 128.9 \end{bmatrix}; \quad \boldsymbol{\Sigma}_{nc} = \begin{bmatrix} 50.1 & -11.1 \\ -11.1 & 23.8 \end{bmatrix}$$

$$P(\omega_c) = 0.09; \quad P(\omega_{nc}) = 0.91$$



**Figura 17 - Convergência dos parâmetros estatísticos das classes de acordo com o número de iterações do algoritmo EM (eixo horizontal) para o primeiro experimento: (a) vetor de médias para a classe mudança ( $\mu_c$ ), (b) vetor de médias para a classe não-mudança ( $\mu_{nc}$ ), (c) matriz de covariâncias para a classe mudança ( $\Sigma_1$ ), (d) matriz de covariâncias para a classe não-mudança ( $\Sigma_2$ ), (e) probabilidades *a priori* para as classes mudança e não-mudança.**

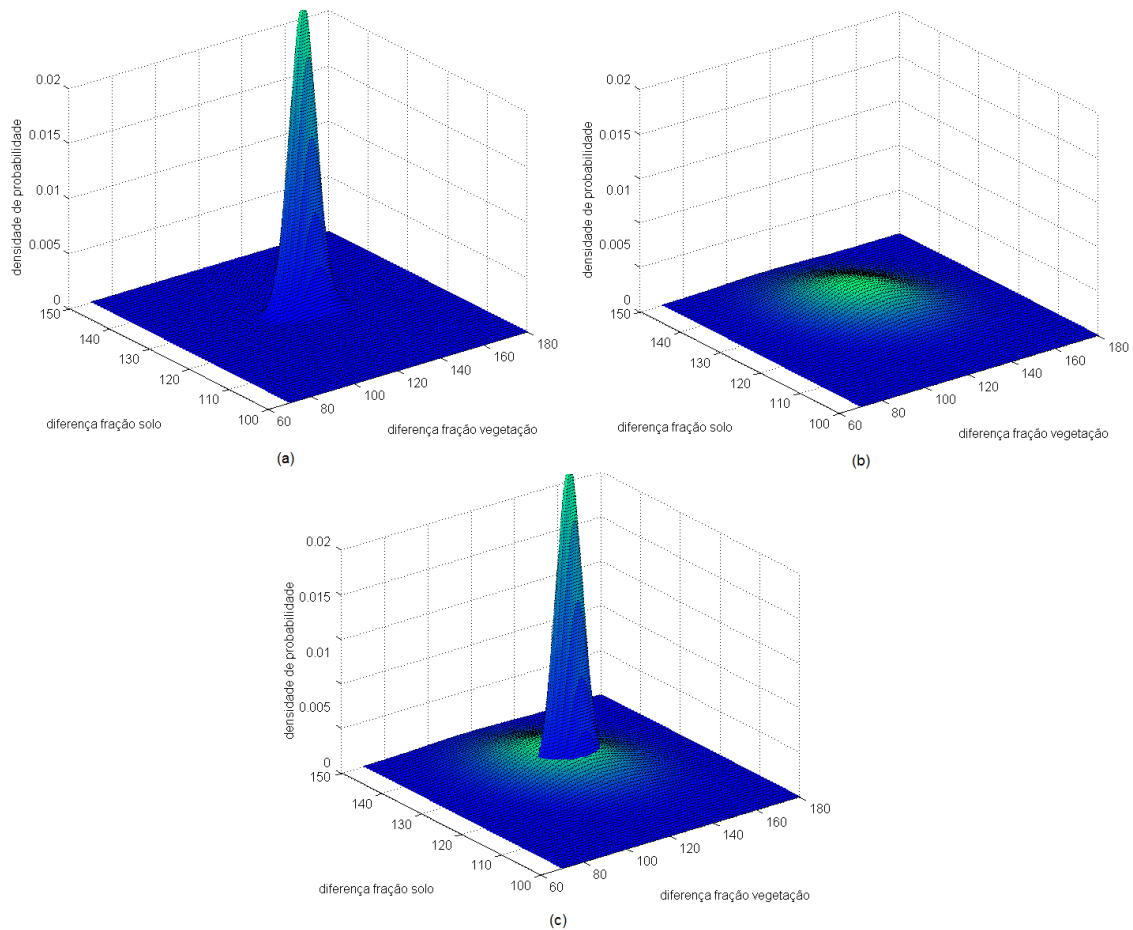
É possível observar uma pequena variação relativa das médias nas Figura 17a e 17b no decorrer do processamento do algoritmo. É interessante notar também como as covariâncias da classe mudança e não-mudança, em vermelho, (Figura 17c e 17d) variam durante o processo de convergência, indicando, para a classe não-mudança, uma baixa covariância e, por conseguinte, baixa correlação entre as imagens de diferença nas frações de vegetação e solo. Para a classe mudança obteve-se um significativo valor negativo para a covariância. Estes resultados confirmam as hipóteses assumidas na seção 3.5 quando da estimação dos valores iniciais para o algoritmo EM.

As suposições sobre as probabilidades *a priori* também podem ser confirmadas a partir da análise dos resultados ilustrados na Figura 17e. A rápida convergência dos valores mostra que a estratégia utilizada para as previsões iniciais de  $P(\omega_c)$  e  $P(\omega_{nc})$  se mostrou adequada<sup>8</sup>.

De posse desses valores, as características das distribuições de probabilidade para as classes mudança e não-mudança podem ser determinadas. A Figura 18 representa as distribuições de probabilidade das imagens de diferença para as frações de vegetação e solo nas classes mudança (Figura 18b) e não-mudança (Figura 18a).

---

<sup>8</sup> Apesar de a estratégia ter mostrado bons resultados para as probabilidades *a priori* nesse experimento específico, isto não deve ser tomado como regra geral, pois, como se trata de uma suposição empírica, nem sempre as previsões se mostrarão condizentes com a realidade.




**Figura 18 - Apresentação das densidades de probabilidade conjuntas das distribuições resultantes das diferenças entre as frações de vegetação e solo para o primeiro experimento: (a) classe não-mudança, (b) classe mudança, (c) sobreposição das classes mudança e não-mudança.**

#### 4.7.3 Produção das imagens de mudanças ocorridas


Para gerar a imagem de mudanças (Figura 19a), a função de decisão Bayesiana é empregada para a estimação dos graus de pertinência de cada pixel na imagem às classes mudança e não-mudança seguindo a abordagem *fuzzy* descrita na seção 3.7. Neste processo, as funções de decisão de Bayes na suposição de normalidade multivariada dos dados é construída empregando os parâmetros estimados por meio do algoritmo EM. Na Figura 18c, estão ilustradas duas funções de decisão de Bayes, associadas às classes mudança e não-mudança, no espaço bi-dimensional das variáveis.





**Figura 19 - Imagem *fuzzy* resultante (tons mais escuros indicam mudanças mais acentuadas).**

Com o objetivo de melhor visualizar os diferentes níveis de cinza presentes na imagem de mudanças, cinco imagens binárias (Figura 20) foram produzidas para os intervalos contínuos de 0 a 0.2, 0.2 a 0.4, 0.4 a 0.6, 0.6 a 0.8 e 0.8 a 1. Para cada imagem, pixels que se encontram dentro do intervalo descrito aparecem em preto enquanto os demais aparecem em branco.



**Figura 20 - Imagens binárias com os graus de pertinência à classe mudança divididos nos seguintes intervalos: (a) 0.0-0.2, (b): 0.2-0.4, (c): 0.4-0.6, (d): 0.6-0.8, (e): 0.8-1.0. Pixels pertencentes ao intervalo são mostrados em preto.**


#### 4.7.4 Inserção de informações de contexto espacial de acordo com a metodologia proposta

As imagens de mudanças mostram forte presença de ruído espacial associado. Inspeccionando visualmente o resultado em comparação com a imagem de referência (Figura 16c e 16d) pode-se constatar que se trata de erros aleatórios.

A inserção de informações de contexto espacial através da metodologia proposta nesta dissertação (seção 3.8) e fundamentada no método de relaxação probabilística (Di Zenzo *et al.* 1986), visa melhorar os resultados da estimação dos graus de pertinência obtidos num primeiro momento. Nesta dissertação, o processo foi implementado de maneira permitir a avaliação a cada passo no processo iterativo da relaxação. A relaxação inicia com os valores estimados para os graus de pertinência. Esses valores são atualizados a cada iteração, até que o critério para convergência seja alcançado. O critério para convergência geralmente está

baseado nas diferenças entre os valores estimados entre duas iterações sucessivas. No presente estudo, foi ativado apenas o critério referente ao número máximo de iterações<sup>9</sup>, forçando a obtenção de um número aceitável de imagens para o estudo detalhado do processo.

A Figura 21 ilustra a convergência do processo de relaxação proposto com 150 iterações.




**Figura 21 - Convergência do processo de relaxação proposto: (a) média das diferenças entre pixels da imagem entre uma iteração e a anterior e (b) média das diferenças entre os pixels da imagem de referência e as imagens geradas pelo processo de relaxação.**

Neste experimento o processo de relaxação converge para um valor próximo de zero no eixo vertical por volta da centésima iteração (Figura 21a). O melhor ajustamento dos valores para os graus de pertinência fica evidenciado pelo aumento na concordância com a imagem de referência (Figura 21b). Os resultados finais da aplicação da metodologia para o experimento 1 podem ser observados nas imagens da Figura 22.

As imagens (c) e (d) da Figura 22 apresentam significativa diminuição do ruído espacial existente nas primeiras iterações. Em comparação com a imagem de referência elas também se apresentam praticamente binarizadas, com valores próximos a zero (cor preta: classe mudança) ou 1 (cor branca, não mudança). A abordagem *fuzzy* não necessariamente exige que o mapa final deva se apresentar de forma distribuída para os níveis de cinza (graus de pertinência). A análise é baseada na idéia de que a inclusão de informações de contexto espacial, quando aplicadas em uma abordagem contínua, resultam em uma contribuição positiva para a acurácia final do mapa de mudanças como mostrado na Figura 21b.

<sup>9</sup> Objetivando o estudo do método, o termo “número máximo de iterações” se transforma, na realidade, em “número desejável de iterações”.




**Figura 22 - Resultados finais para o experimento 1: (a) antes do processo de relaxação, (b) após 10 iterações do processo e (c) após 100 iterações. As alterações variam continuamente de mudança (preto) para não-mudança (branco).**

## 4.8 Experimento empregando imagens *Landsat 5-TM* reais para as duas datas

### 4.8.1 Descrição das imagens usadas

Para o segundo experimento foram consideradas duas imagens *Landsat 5-TM* cobrindo a mesma área teste do experimento anterior. A imagem da primeira data (Outubro de 1991) corresponde à mesma utilizada no experimento anterior (Figura 11a). A imagem da segunda data foi adquirida em Abril de 1994 (Figura 23a). As imagens fração para a segunda imagem foram obtidas da mesma forma, utilizando o MLME conforme a seção 4.43.4 com as componentes definidas da mesma forma que o primeiro experimento. As frações resultantes para vegetação, solo e sombra/água são mostradas na Figura 23b, 23c e 23d, respectivamente.




**Figura 23 - Imagem *Landsat* de Abril de 1994 utilizada no segundo experimento como data 2: (a) composição em falsa cor 5(R) 4(G) 3(B), (b) fração de vegetação, (c) fração de solo e (d) fração de sombra. Variação contínua de preto (0% da componente) a branco (100% da componente).**

#### 4.8.2 Produção das imagens de diferença


As imagens de diferença para o segundo experimento (Figura 24) foram geradas da maneira exposta na seção 4.6: subtração pixel a pixel nas frações correspondentes das duas datas. Tons mais claros simbolizam mudanças positivas na fração, isto é, um incremento na

fração da componente da primeira para a segunda data. Tons mais escuros simbolizam mudanças negativas, isto é, redução na fração ocupada pela componente durante o tempo decorrido entre a primeira e a segunda data considerada. Pode-se notar que na Figura 24a, imagem de diferenças na fração de vegetação, existe uma região mais clara marcada pela letra A (Figura 24a). Esse fato sugere uma mudança positiva na fração de vegetação da primeira para a segunda data que na verdade foi causada pela presença de nuvens na primeira imagem. De maneira inversa, a região marcada com a letra B demonstra uma diminuição da área vegetada (mudança negativa). Nesse caso a presença de nuvem ocorreu na segunda imagem, causando a impressão de que houve uma redução da área coberta por vegetação e um aumento na fração correspondente ao solo na região.

Pela análise visual das imagens de diferença, é de grande esperança que as regiões cobertas por nuvem, assim como a região central do platô e algumas áreas da porção inferior esquerda da imagem, apareçam no mapa de mudanças gerado automaticamente pela metodologia.



**Figura 24 - Imagem de diferença produzida por subtração para o segundo experimento no formato byte (0-255) para a fração de (a) vegetação e (b) solo. As setas indicadas pelas letras A e B correspondem a falsas mudanças no terreno provocadas pela presença de nuvens nas imagens, sendo B nuvem na primeira imagem e A nuvem na segunda.**



**Figura 25 - Histogramas da imagem de diferenças: (a) diferença entre as frações de vegetação e (b) diferenças entre as frações de solo.**

#### 4.8.3 Estimação dos parâmetros das distribuições e das probabilidades *a priori* das classes mudança e não-mudança.

Neste segundo experimento, os parâmetros iniciais do algoritmo EM para a classe mudança e não-mudança foram estimados seguindo o método proposto na seção 3.5. A transformação de Karhunen-Loeve aplicada para as diferenças nas componentes de vegetação e solo produz os seguintes resultados para a matriz de autovetores ( $\mathbf{V}$ ) e correspondente matriz de autovalores ( $\mathbf{D}$ ):

$$\mathbf{V} = \begin{bmatrix} -0.73 & -0.68 \\ -0.68 & 0.73 \end{bmatrix} \quad \mathbf{D} = \begin{bmatrix} 68 & 0 \\ 0 & 160.3 \end{bmatrix}$$

Os parâmetros iniciais foram definidos como:

$$\boldsymbol{\mu}_c = \begin{bmatrix} 131.1 \\ 137.2 \end{bmatrix} \quad \boldsymbol{\Sigma}_c = \begin{bmatrix} 111.1 & -46.1 \\ -46.1 & 117.3 \end{bmatrix} \quad \boldsymbol{\mu}_{nc} = \begin{bmatrix} 127.5 \\ 127.5 \end{bmatrix} \quad \boldsymbol{\Sigma}_{nc} = \begin{bmatrix} 68 & 0 \\ 0 & 68 \end{bmatrix}$$

Da mesma forma que no primeiro experimento, os valores iniciais para as probabilidades *a priori*, foram fixados em  $P(\omega_c)=0.1$  e  $P(\omega_{nc})=0.9$ , com  $\omega_c$  e  $\omega_{nc}$  representando as classes mudança e não-mudança respectivamente.

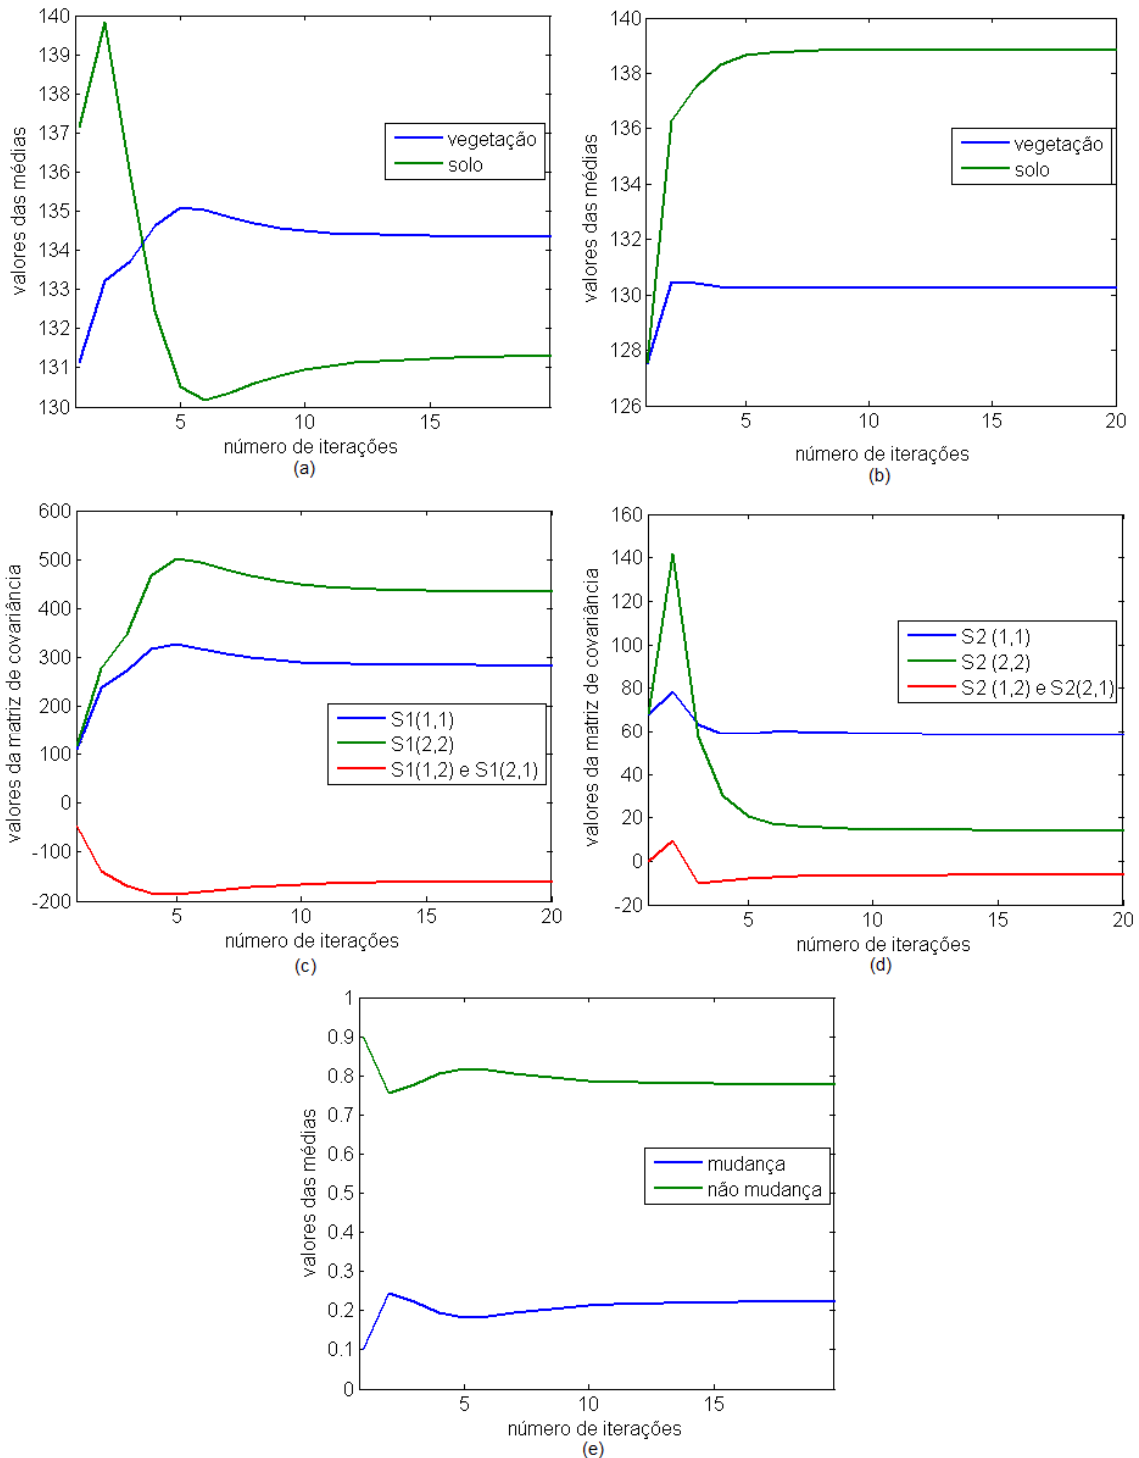
Após 10 iterações o algoritmo obteve a convergência (Figura 26) apresentando os seguintes valores:



$$\boldsymbol{\mu}_c = \begin{bmatrix} 134.3 \\ 131.3 \end{bmatrix}; \boldsymbol{\Sigma}_c = \begin{bmatrix} 283.1 & -160.3 \\ -160.3 & 433.2 \end{bmatrix}; \boldsymbol{\mu}_{nc} = \begin{bmatrix} 130.2 \\ 138.8 \end{bmatrix}; \boldsymbol{\Sigma}_{nc} = \begin{bmatrix} 58.1 & -6.5 \\ -6.5 & 14.1 \end{bmatrix}$$

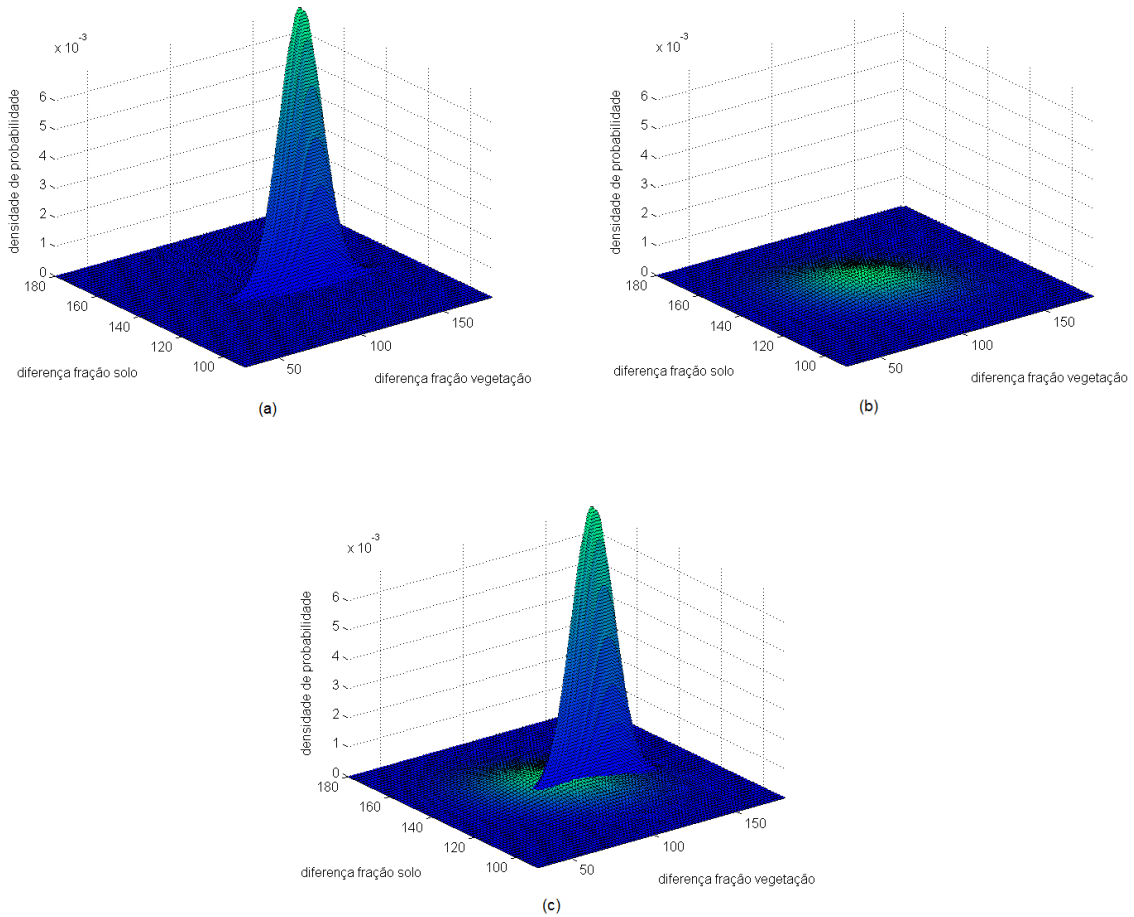
$$P(\omega_c) = 0.22; P(\omega_{nc}) = 0.78$$

Os valores para o vetor de médias das duas variáveis estão ilustrados na Figura 26a e 26b. Pode-se observar que a primeira variável (média para a diferença na componente vegetação) mantém uma tendência de convergência ao longo das várias iterações para um valor próximo dos valores iniciais definidos. Já a segunda variável (média para a diferença na componente solo) apresentou uma variação um pouco maior que a ao longo do processo iterativo, contudo a convergência também ocorreu em valores próximos aos definidos inicialmente. Estes resultados mais uma vez tendem a confirmar a eficiência da estratégia adotada para definição dos valores iniciais para os vetores de médias. Com relação aos valores finais estimados para as matrizes de covariância, observa-se que para a classe mudança as duas componentes (vegetação e solo) apresentaram covariância negativa como esperado. As variâncias para essa classe mantiveram valores altos. Também dentro do esperado, as matrizes de covariância para a classe não-mudança apresentaram valores muito próximos daqueles definidos na iteração inicial com base na metodologia proposta na seção 3.5, ou seja, valores de covariância próximos de zero e variâncias relativamente baixas. A convergência das probabilidades *a priori* para as duas classes corrobora a inferência de que a ocorrência da classe não-mudança é, nesse experimento, superior a da classe mudança.



**Figura 26 - Convergência dos parâmetros estatísticos das classes de acordo com o número de iterações do algoritmo EM (eixo horizontal) para o primeiro experimento: (a) vetor de médias para a classe mudança ( $\mu_c$ ), (b) vetor de médias para a classe não mudança ( $\mu_{nc}$ ), (c) matriz de covariâncias para a classe mudança ( $\Sigma_1$ ), (d) matriz de covariâncias para a classe não mudança ( $\Sigma_2$ ), (e) probabilidades *a priori* para as classes mudança e não-mudança.**


Assim como no primeiro experimento relativo à imagem sintética, as funções de decisão de Bayes para as duas classes podem ser construídas a partir dos parâmetros encontrados pelo algoritmo EM. A crista resultante para a classe não-mudança (Figura 27a) é mais larga (apresenta maiores variâncias nas diferenças das componentes) do que àquela encontrada no experimento com os dados sintéticos. Isso é ocasionado porque além das mudanças aleatórias causadas por ruído apresentadas na imagem de diferença ocorrem ainda pequenas diferenças entre as duas imagens que são causadas pela grande defasagem de datas em que foram tomadas; diferenças que normalmente não são de interesse prático. A sobreposição das duas distribuições de probabilidade (Figura 27c) mostra que os graus de pertinência ficarão menos saturados para o zero ou 1 devido a maior variância das gaussianas quando comparados com os resultados do primeiro experimento. Isso significa que na imagem *fuzzy* que ilustra os graus de pertinência (Figura 28) ocorre um número de pixels com valores intermediários para os graus de pertinência, maior do que aquele encontrado no primeiro experimento.




**Figura 27 - Apresentação das densidades de probabilidade conjuntas das distribuições resultantes das diferenças entre as frações de vegetação e solo para o segundo experimento: (a) classe não-mudança, (b) classe mudança, (c) sobreposição das classes mudança e não-mudança.**

#### 4.8.4 Produção das imagens de mudanças ocorridas

A imagem *fuzzy* resultante do segundo experimento (Figura 28) mostra ruído espacial acentuado assim como o primeiro experimento. As nuvens presentes nas duas cenas aparecem na imagem como regiões bastante escuras, já que tons mais escuros indicam maiores mudanças. Assim como no primeiro experimento, com a intenção de melhorar a visualização dos diferentes níveis de cinza presentes na imagem de mudanças, cinco imagens binárias (Figura 29) foram produzidas para os intervalos contínuos de 0 a 0.2, 0.2 a 0.4, 0.4 a 0.6, 0.6 a 0.8 e 0.8 a 1.



**Figura 28 - Imagem *fuzzy* resultante do segundo experimento (tons mais escuros indicam mudanças mais acentuadas).**




**Figura 29 - Imagens binárias com os graus de pertinência à classe mudança para o segundo experimento divididos nos seguintes intervalos: (a) 0.0-0.2, (b): 0.2-0.4, (c): 0.4-0.6, (d): 0.6-0.8, (e): 0.8-1.0. Pixels pertencentes ao intervalo são mostrados em preto.**

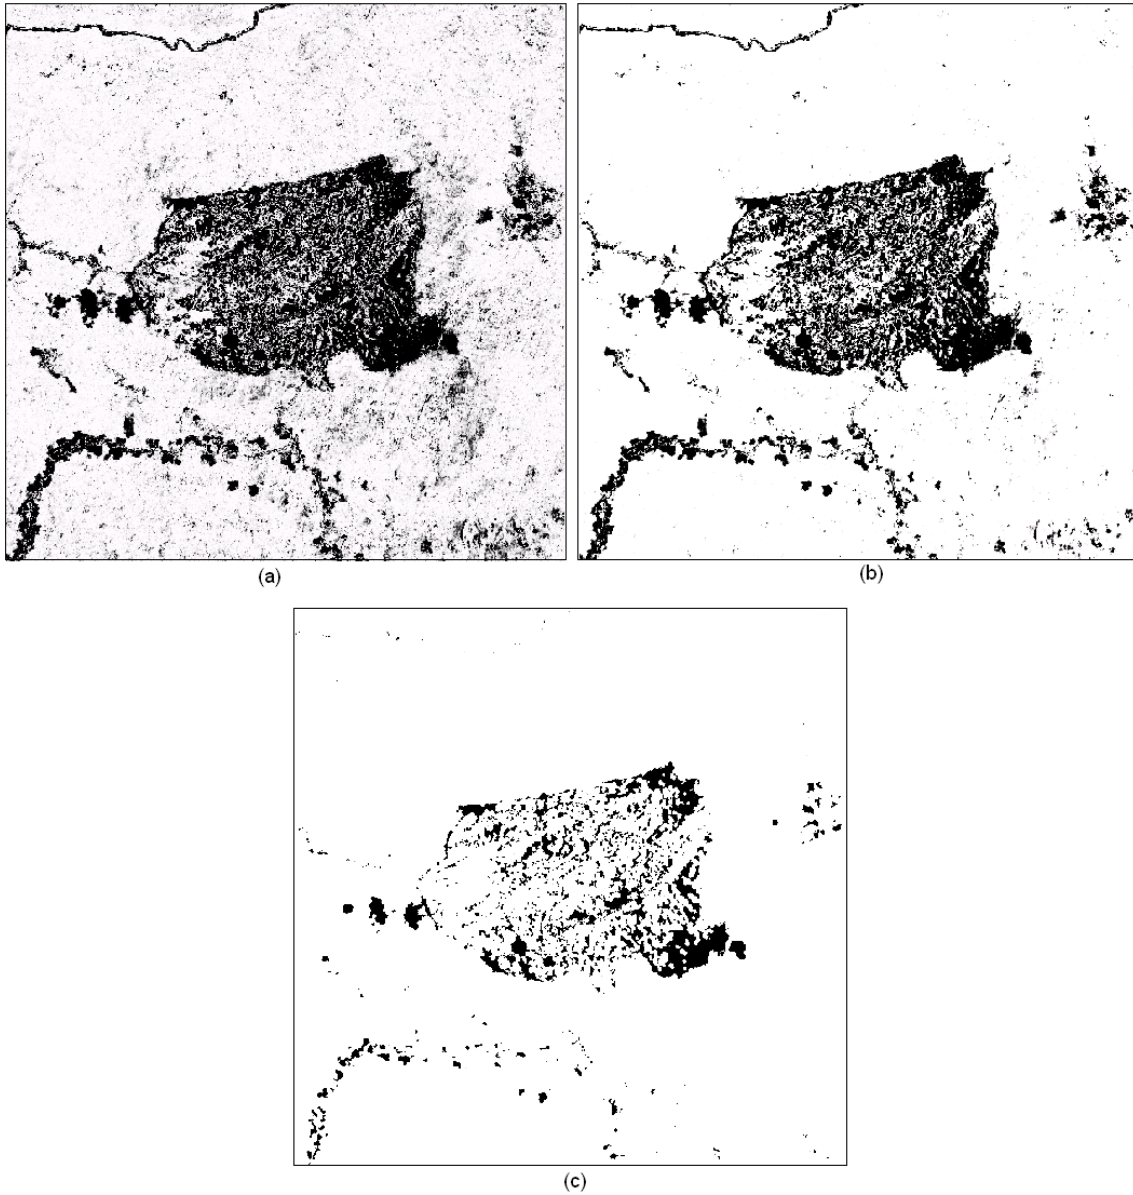
#### 4.8.5 Inserção do contexto espacial de acordo com a metodologia proposta

Seguindo a metodologia proposta na seção 3.8, a imagem com os graus de pertinência à classe mudança foi submetida a 100 iterações do algoritmo proposto para inserção do contexto espacial. Os resultados das médias das diferenças entre os elementos das imagens em duas iterações consecutivas estão representados na curva da Figura 30. A convergência é visualizada pela tendência que a curva toma nas consecutivas iterações da Figura 30. Em geral é observado que por volta da décima iteração o processo praticamente não introduz nenhuma contribuição adicional significativa aos graus de pertinência. Três imagens de estágios intermediários do processo são mostradas na Figura 31. Apesar de uma análise quantitativa não ser possível na imagem do segundo experimento por não haver dados de referência, algumas conclusões podem ser tiradas comparando os resultados encontrados pela metodologia proposta com os experimentos realizados para a mesma imagem em Haertel *et al.* (2004), onde um processo de *clustering* foi aplicado para as diferenças nas frações de

vegetação, solo e sombra/água produzindo um número de *clusters*. Usando informações disponíveis para esse trabalho, os autores foram capazes de atribuir cada *cluster* a uma mudança específica como desflorestamento, desflorestamento seguido de rebrota e áreas de mineração. Uma inspeção visual das áreas mostrando os graus de pertinência à classe não-mudança produzidos pela metodologia proposta apresentam resultados que são bastante similares àqueles encontrados pelos autores, particularmente nas primeiras iterações do processo de relaxação, sugerindo a adequação da metodologia proposta.



**Figura 30 - Convergência do processo de relaxação proposto: média das diferenças entre pixels das imagens para duas iterações consecutivas.**



**Figura 31 - Resultados finais para o experimento 2: (a) antes do processo de relaxação, (b) após 10 iterações do processo e (c) após 100 iterações. As alterações variam continuamente de mudança (preto) para não-mudança (branco).**

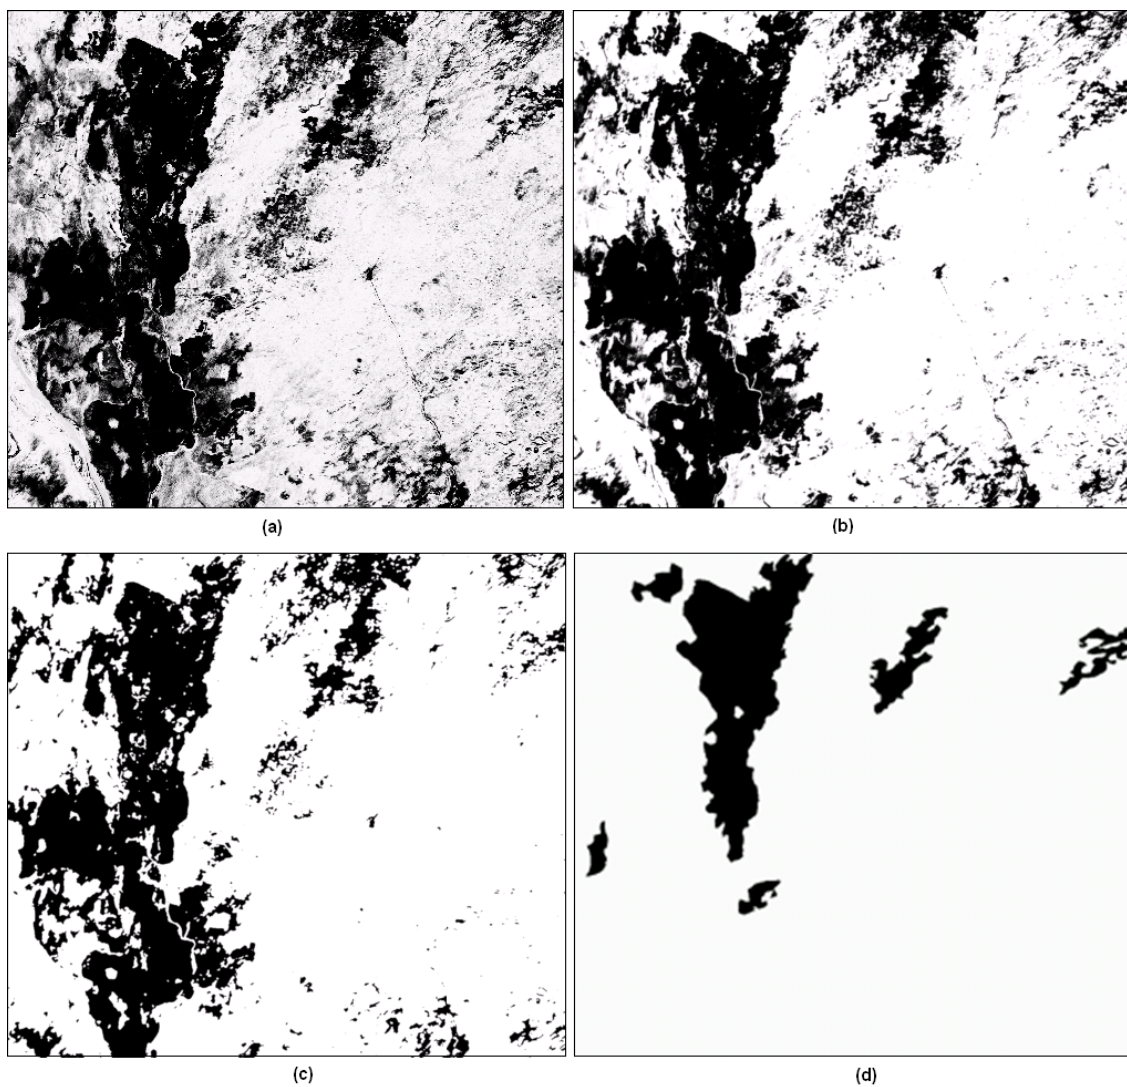


## 4.9 Experimento empregando imagens CBERS-2B de região atingida por queimada no Pantanal.

Para este experimento foram consideradas duas imagens CBERS-2B, sensor CCD, cobrindo uma área do Pantanal brasileiro na cidade de Corumbá-MS. A imagem da primeira data corresponde ao dia 12/04/2009, enquanto a segunda ao dia 20/06/2009. As imagens fração foram obtidas utilizando o MLME conforme a seção 3.4 com as componentes definidas da mesma forma que os experimentos anteriores. Depois de geradas as imagens de diferença, os parâmetros estatísticos das distribuições de probabilidade das classes mudança e não-mudança foram estimados conforme as seções 3.5 e 3.6. Os parâmetros foram usados para calcular os graus de pertinência às classes mudança e não-mudança conforme a seção 3.7.


A imagem *fuzzy* resultante é mostrada na Figura 32, e as subseqüentes imagens produzidas pela aplicação do refinamento proposto usando informações de contexto espacial com 10 e 100 iterações, respectivamente, estão mostradas nas Figura 32b e 32c.

Com base em dados fornecidos pela Empresa Brasileira de Pesquisas Agropecuárias – EMBRAPA-PANTANAL, foi produzido um mapa binário indicando a presença de queimadas na região imageada. Com base em análise visual desse mapa, pode-se constatar que áreas marcadas pela presença de ruídos aleatórios na Figura 32a (região cinza), e que são eliminadas após aplicação da metodologia de análise do contexto espacial proposta (Figura 32b e Figura 32c), correspondem a regiões que não foram atingidas por queimada (Figura 32d). Ainda em comparação visual, nota-se que essa foi a maior contribuição da metodologia proposta para o melhoramento dos resultados, pois a homogeneidade das regiões presentes na Figura 32 não é alcançada pela aplicação das informações de contexto. Algumas áreas na parte superior das imagens CBERS-2B estudadas corresponde a regiões com presença de alagamentos, fator que dificulta a aplicação da metodologia proposta para detecção exclusiva de queimadas, já que a modelagem proposta foi implementada com o objetivo de detectar qualquer tipo de mudança ocorrente entre as duas datas.



**Figura 32 - Resultados finais para o experimento 3: (a) antes do processo de relaxação, (b) após 10 iterações do processo, (c) após 100 iterações e (d) imagem binária de referência com base em dados da EMBRAPA. As alterações variam continuamente de mudança (preto) para não-mudança (branco).**

A curva da Figura 33 mostra os resultados das médias das diferenças entre os elementos das imagens em duas iterações consecutivas.



**Figura 33 - Convergência do processo de relaxação proposto: média das diferenças entre pixels das imagens para duas iterações consecutivas.**

#### 4.10 Custo computacional

Para a análise do custo computacional do processo completo, foi utilizado um computador do tipo PC com um Microprocessador 1.6 GHz AMD Turion 64 X2 Dual-Core Mobile Technology TL-52, memória *cache* do processador 512KB+512KB L2 e memória RAM de 2x1024 MB. Os processos considerados para essa análise estão mostrados na Tabela 1. A imagem utilizada para a análise foi a imagem *Landsat 5-TM* de dimensões 625x625x6.

Produção das imagens fração	Estimação dos parâmetros estatísticos pelo algoritmo EM	Introdução e informações de contexto espacial
3:30h, com processamento utilizando os dois cores do processador	0.5s / iteração	9s / iteração

**Tabela 1 – Custo computacional do processo.**

Em termos computacionais, o processo de detecção sugerido nessa dissertação precisa ser otimizado caso grandes volumes de dados precisem ser processados em tempo aceitável.

Rotinas como a estimação dos parâmetros estatísticos através do algoritmo EM, o cálculo dos graus de pertinência através da abordagem *fuzzy*, e a inserção de informações de contexto espacial pelo processo de relaxação proposto, tornam-se consideravelmente mais rápidas com o processamento vetorial disponível na representação de imagens por vetores (ex: formato ERDAS 7.x). No entanto, o processo fracionamento da imagem em componentes demanda um tempo consideravelmente maior (cerca de 90% do tempo total do processamento). Esse tempo decorre da impossibilidade de implementar o MLME de forma vetorial, já que cada pixel sofre um processo de ajustamento numérico individual pelo Método dos Mínimos Quadrados. Porém, processamentos paralelos do tipo *multi-core* ou *cluster* podem tornar procedimentos paralelizáveis (caso do MLME) substancialmente mais velozes. Além disso, o processamento de imagens através de placas de vídeo que possuem Unidade de Processamento Gráfico (GPU), as quais possuem a capacidade de processar gráficos com maior eficiência que processadores normais por contar com uma estrutura de processamento vetorial, vem sendo bastante utilizado para acelerar processamentos do tipo laços iterativos.

## 5 CONCLUSÕES E SUGESTÕES

### 5.1 Conclusões

Nesta dissertação propõe-se uma metodologia para fins de detecção de mudanças ocorridas em cenas naturais, com base na análise de imagens multitemporais. Um dos aspectos relevantes consiste na proposta de uma abordagem *fuzzy* na detecção de alterações ocorridas na cena. Esta abordagem permite uma modelagem mais acurada de alterações que ocorrem em cenas naturais, entre duas datas distintas. Para a realização deste objetivo, a metodologia proposta desenvolve a análise das imagens multitemporais em nível de sub-pixel. A análise é portanto desenvolvida a partir de imagens fração, estimadas para cada uma das duas datas. Os graus de pertinência para as classes mudança e não-mudança são então estimados para cada pixel na imagem a partir das mudanças ocorridas nas correspondentes frações entre as duas datas. Nesta dissertação é também proposto que os graus de pertinência às classes mudança e não-mudança sejam estimados dentro de uma abordagem Bayesiana, seguindo uma lógica *fuzzy*. Propõe-se aqui que os parâmetros para as funções densidade de probabilidade são estimados de uma forma iterativa empregando o algoritmo *Expectation-Maximization* (EM); as imagens de diferença de frações são entendidas como uma mistura de amostras pertencentes à duas distribuições distintas: mudança e não-mudança. Nesse estudo é proposto estimar os valores iniciais do algoritmo EM diretamente da distribuição dos dados das imagens de diferença para as frações de vegetação e solo assumindo a existência de uma correlação entre essas duas variáveis. Nessa abordagem os pixels da imagem não recebem um rótulo único a uma das classes, mas sim um grau de pertencimento a uma e a outra. Como em cenas naturais as alterações temporais mostram a ocorrência de uma correlação espacial, nesse estudo foi proposta a inserção de informações de contexto espacial através de um processo de relaxação com o intuito de incrementar a acurácia nos valores estimados para a pertinência de cada pixel individual as classes mudança e não-mudança.

Os experimentos desenvolvidos nesta dissertação ilustram a adequação da metodologia proposta produzindo resultados bastante aceitáveis na detecção quantitativa de alterações na cobertura do solo. O método proposto para a escolha *a priori* dos parâmetros estatísticos de entrada para o algoritmo EM se mostrou eficiente, levando a convergência dos

parâmetros em menor tempo. Os graus de pertinência estimados a partir de um suporte Bayesiano produziram boas estimativas das mudanças ocorridas na cena. A inserção de informações de contexto espacial pelo processo de relaxação proposto nesse estudo provou funcionar de forma satisfatória como evidenciado nas curvas de pertinência construídas para o primeiro experimento, especialmente para remover o ruído aleatório presente nos dados.

O método proposto nesse estudo visa detectar mudanças em ambientes onde há prevaletimento de vegetação e solo. Sendo assim, possui algumas restrições quanto ao uso para outros ambientes com diferentes componentes, principalmente no que tange o método proposto para determinação dos valores iniciais do algoritmo EM. Tratando-se ainda desse algoritmo, deve-se salientar que o processo converge para valores confiáveis desde que haja uma proporção razoável entre as duas distribuições, ou seja, o método não alcançará a convergência se uma das duas classes contiver um número muito superior de representantes.

## 5.2 Sugestões

Uma dificuldade comum a todos os métodos de detecção de alterações com base em imagens multitemporais consiste na presença de erros residuais no registro das imagens adquiridas em datas diferentes. Como a metodologia aqui proposta trabalha em um nível de subpixel, é necessário que o registro das imagens seja executado com uma precisão compatível. Como proposta para trabalhos futuros dentro desse tópico sugere-se portanto que sejam investigados métodos voltados para a redução do erro no registro. Um outro problema que necessita atenção refere-se a variações na componente sombra, causadas não por alterações efetivamente ocorridas na cena, mas por variações nas condições de iluminação da mesma. A variação da componente sombra causada pelo diferente ângulo de iluminação solar em diferentes épocas do ano resulta em flutuações não aleatórias nas frações das componentes em análise, podendo portanto serem modeladas. Modelagens precisas da fração de sombra em diferentes períodos do ano devem contribuir para um resultado final mais confiável. Outro tópico adequado para futuros estudos consiste na investigação sobre quais as classes componentes (*endmembers*) mais adequados para cada cena em particular. Nessa dissertação foi abordada a contribuição do contexto espacial por um processo de relaxação adaptado. O desenvolvimento de novos métodos de inserção do contexto espacial seguindo uma lógica *fuzzy* também é altamente encorajado.

## REFERÊNCIAS BIBLIOGRÁFICAS

BAZI, Y.; BRUZZONE, L.; MELGANI, F., An unsupervised approach based on the generalized Gaussian model to automatic change detection in multitemporal SAR images, *IEEE Trans. Geosci. Remote Sens.*, vol. 43, no. 4, pp. 874-887, 2005.

BISHOP, C. M., *Pattern Recognition and Machine Learning*, New York: Springer, 2006.

BOVOLO, F., A Multilevel Parcel-Based Approach to Change Detection in Very High Resolution Multitemporal Images, *IEEE Geosci. Remote Sens. Letters* , vol. 6, no. 1, pp. 33-37, 2009

BOVOLO, F.; BRUZZONE, L.; MARCONTINI, M., Novel Approach to Unsupervised Change Detection Based on a Semisupervised SVM and a Similarity Measure, *IEEE Trans. Geosci. Remote Sens.*, vol. 46, no. 7, pp. 2070-2082, 2008.

BRUZZONE, L.; PRIETO, D. F., Automatic Analysis of the Difference Image for Unsupervised Change Detection, *IEEE Trans. Geosci. Remote Sens.*, vol. 38, no. 3, pp. 1171-1182, 2000.

BRUZZONE, L.; COSSU, R., An Adaptive Approach for Reducing Registration Noise Effects in Unsupervised Change Detection, *IEEE Trans. Geosci. Remote Sens.*, vol. 41, no. 11, pp. 2455-2465, 2003.

BRUZZONE, L.; COSSU, R.; VERNAZZA, G. Detection of land-cover transitions by combining multirate classifiers, *Pattern Recognition Letters*, vol. 25, no. 13, pp. 1491-1500, 2004.

DALLA MURA, M.; BENEDIKTSSON; J.A.; BOVOLO; F., BRUZZONE, L., An Unsupervised Technique Based on Morphological Filters for Change Detection in Very High Resolution Images, *IEEE Trans. Geosci. Remote Sens.*, vol. 5, no. 3, pp. 433-437, 2008.

DEMPSTER, A.P.; LAIRD, N.M.; RUBIN, D.B., Maximum Likelihood from Incomplete Data via the EM Algorithm. *J. Royal Stat. Society.*, Series B (Methodological) 39 (1): 1-38, 1977.

DI ZENZO S.; BERNSTEIN, R.; DeGLORIA, S. D.; KOLSKY H. G. Gaussian maximum likelihood and contextual classification algorithms for multicrop classification. *IEEE Trans. Geosci. Remote Sens.*, vol. GE-25, no. 6, pp. 805-814, 1987.

DUDA, R. O.; HART, P. E.; STORK, D. G., *Pattern Classification*, 2<sup>nd</sup> edition, New York: John Wiley & Sons, 2001.

FUNG, T., An assessment of TM imagery for land-cover change detection, *IEEE Trans. Geosci. Remote Sens.*, vol. 28, no. 4, pp. 681-684, 1990.

GHOSH, S.; BRUZZONE, L.; PATRA, S.; BOVOLO, F.; GHOSH, A., A Context-Sensitive Technique for Unsupervised Change Detection Based on Hopfield-Type Neural Networks, *IEEE Trans. Geosci. Remote Sens.*, vol. 45, no. 3, pp. 778-789, 2007.

HAERTEL, V.; SHIMABUKURO, Y. E.; ALMEIDA FILHO, R. Fraction Images in Multitemporal Change Detection, *Int. J. Remote Sens.*, vol. 10, no. 23, pp. 5473-5489, 2004.

HAERTEL, V.; SHIMABUKURO, Y. E. Spectral Linear Mixing Model in Low Spatial Resolution Image Data, *IEEE Trans. Geosci. Remote Sens.*, vol. 43, no. 11, pp. 2555-2562, 2005.

HSIEH, C.; HSIEH, P.; LIN, C.; Subpixel Change Detection Based on Abundance and Slope Features, *Proceedings of the International Geoscience and Remote Sensing Symposium July 31-Aug. 4* pp.775 – 778, 2006.

HALL, F. G.; STREBEL, D. E.; NICKESON, J. E.; GOETZ, S. J. Radiometric rectification: toward a common radiometric response among multirate, multisensor images, *Remote Sens. Environ.*, vol. 35, pp. 11-27, 1991.

Instituto Nacional de Pesquisas Espaciais (INPE) Website: <http://www.cbers.inpe.br>. Acessado em Novembro de 2009.

LI, S. Z., Markov Random Field Modelling in Computer Vision, *Computer Science Workbench*, T. L. Kunii (ed). Berlin: Springer-Verlag, 1995.

MALILA, W. A. Change Vector Analysis: An Approach for Detecting Forest Changes with Landsat, *Proceedings of the LARS Machine Processing of Remotely Sensed Data Symposium*, pp. 326-336, 1980.

MELGANI, F.; SERPICO, S.B., A Markov Random Field Approach to Spatio-Temporal Contextual Image Classification, *IEEE Trans. Geosci. Remote Sens.*, vol. 41, no. 11, pp. 2478-2487, 2003.



MICHALEK, J. L.; WAGNER, T. W.; LUCZKOVICH, J. J.; TOFFLE, R. W., Multispectral Change Vector Analysis for Monitoring Coastal Marine Environments, *Photogramm. Eng. Remote Sens.*, vol. LIX, no. 3, pp. 381-384, 1993.

*National Aeronautics and Space Administration (NASA)* Website: <http://landsat.gsfc.nasa.gov/about/landsat5.html>. Acessado em Julho de 2009.

RADKE, J. R.; ANDRA, S., AL-KOFAHI, O.; ROYSAM, B.; Image change detection algorithms: a systematic survey”, *IEEE Trans. Image Process.*, vol. 14, no. 3, pp. 294-307, 2005.

RICHARDS, J. A.; JIA, X., *Remote Sensing Digital Image Analysis*. Third Edition. New York: Springer, 1999.

SCHNEIDER, R. Z.; FERNANDES, D., Entropy Among a Sequency of SAR Images for Change Detection, *Proceedings of the International Gescience and Remote Sensing Symposium*, vol. 2, pp.1389-1391, 2003.

SERPICO, S. B.; BRUZZONE, L.; ROLI, F. GOMARASCA, M., An automatic technique for detecting land-cover transitions. *In: Proceedings of "IEEE-IGARSS '96"*, Lincoln, USA May, pp. 1382-1384, 1996.

SHIMABUKURO, Y.E.; SMITH, J.A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data, *IEEE Trans. Geosci. Remote Sens.*, vol. 29, no. 1, pp.16-20, 1991.

SINGH, A., Digital change detection techniques using remotely-sensed data, *Int. J. Remote Sens.*, vol. 10, no. 6, pp. 989-1003. 1989.

TERRIEN, C. W. Decision, estimation, and classification: an Introduction to Pattern Recognition and Related Topics. New York: Wiley, 1989.

THEODORIDIS, S., E KOUTROUMBAS, K., *Pattern Recognition*, 2<sup>nd</sup> edition, Amsterdam: Elsevier-Academic Press, 2003.

TSO, B. E MATHER, P. M. *Classification Methods for Remotely Sensed Data*. London and New York: Taylor & Francis, 2001.

XIAOLONG, D; KHORRAM, S., The effects of image misregistration on the accuracy of remotely sensed change detection, *IEEE Trans. Geosci. Remote Sens.*, vol. 36, no. 5, pp.1566-1577, 1998.

## 6 APÊNDICE: CÓDIGO FONTE (LINGUAGEM MATLAB)

### 1) Função para fracionamento da imagem

```
function [imgfr6] = imgfracao6(img,varargin)
%-----
% Essa função produz as componentes de fração da imagem de entrada (img)
% conforme as instruções abaixo:
%
% INPUT:
% "img": imagem to be fractioned in: (1)vegetation, (2)soil, (3)shade, ...
%          in byte format (0-255)
%          format: ERDAS 7.4
% Example:
% b1=input_values_b1; % |a11 a12 a13| (veg, soil, shade) for band 1
%
% b2=input_values_b2; % |a21 a22 a23| (veg, soil, shade) for band 2
%
% b3=input_values_b3; % |a31 a32 a33| (veg, soil, shade) for band 3
%
% Example: (veg, soil, shade)
%   If
%       X = imgfracao6(a,[150 120 100],[80 70 60],[50 90 110]);
%
%           ^       ^           ^           ^
%           |       |           |           |
%           image  band1       band2       band3
%10/03/09
%-----
%
% start iterative procedure
%
siz=size(img);
nb=siz(1,2); %nb=number of bands in a E7.4 formatted image
np=siz(1,1); %np=number of pixels in a E7.4 formatted image

v=cell2mat(varargin); % Convert the contents of the cell array (varargin)
%into a single matrix

optargin=size(varargin);
if optargin(1,2)~= siz(1,2)
    error('Number of input arguments do not agree with image band number')
end
cl=size(varargin{1,1},2);
```

```

n=-1;
for i=1:nb
    n=n+1;
    for j=1:cl
        A(i,j)=v(1,(n*cl)+j);% Create the matrix of pure radiance targets
    end
end

lb = zeros(cl,1);
ub = ones(cl,1);
Aeq= ones(1,cl);
beq= [1];
for i=1:np
    R=(img(i,:))';%Create the pixels band radiance for the three targets
    imgfr6(i,:) = lsqin(A,R,[],[],Aeq,beq,lb,ub);
end
clc

```

## 2) Função acelerada para fracionamento da imagem a partir de segmentos da imagem e operações paralelas do tipo *multi-core*

```

function [imgfr] = imgfracao_ultimo_rapido(img,varargin)

%-----
% Essa função produz as componentes de fração da imagem de entrada (img)
% conforme as instruções abaixo a partir de um número de segmentos
% processados em seqüência:
%
% INPUT:
% "img": imagem to be fractioned in: (1)vegetation, (2)soil, (3)shade, ...
%          in byte format (0-255)
%          format: ERDAS 7.4
%
% Exemple:
% b1=input_values_b1; % |a11 a12 a13| (veg, soil, shade) for band 1
%
% b2=input_values_b2; % |a21 a22 a23| (veg, soil, shade) for band 2
%
% b3=input_values_b3; % |a31 a32 a33| (veg, soil, shade) for band 3
%
% Example: (veg, soil, shade)
%   If
%       X = imgfracao6(a,[150 120 100],[80 70 60],[50 90 110]);
%
%           ^       ^       ^       ^
%           |       |       |       |
%           image  band1   band2   band3
%
%09/10/09
%-----

```

```

%
% start iterative procedure
%
iter=0;
siz=size(img);
nb=siz(1,2); %nb=number of bands in a E7.4 formatted image
np=siz(1,1); %np=number of pixels in a E7.4 formatted image

v=cell2mat(varargin); % Convert the contents of the cell array (varargin)
into a single matrix

optargin=size(varargin);
if optargin(1,2)~= siz(1,2)
    error('Number of input arguments do not agree with image band number')
end
cl=size(varargin{1,1},2);

n=-1;
for i=1:nb
    n=n+1;
    for j=1:cl
        A(i,j)=v(1,(n*cl)+j);% Creates the matrix of values of pure radiance
targets (endmembers)
    end
end

lb = zeros(cl,1); % constraints 0 <= x(i) <= 1
ub = ones(cl,1); %
Aeq= ones(1,cl); % constraint 0 <= x1+x2+...x(i) <= 1
beq= [1]; %
%
%divisão da imagem:
div=(round(np/10000))-1;
resto=np-div;
for i=1:10000

parfor j=1:div
    R=(img(i+(j-1)*1000,:))'; % create the pixels band radiance for the
targets
    imgfr(i,j,:) = lsqlin(A,R,[],[],Aeq,beq,lb,ub);
iter=iter+1
end
end
%parfor i=1:resto
    % R=(img((div*1000)+i,:))'; % create the pixels band radiance for the
targets
    % imgfr(i,1001,:) = lsqlin(A,R,[],[],Aeq,beq,lb,ub);

%end
clc

```

### 3) Função para resolver o problema da mistura das densidades de probabilidade (algoritmo EM)

```

function [M1,M2,S1,S2,P,MM1,MM2,SS1,SS2,PP] = density_mixture_Mar_26_...
    ultimo(dif_byte_no_noise,M1,M2,S1,S2,P,max_iter)

%-----
% Essa função resolve o problema da mistura de densidades. Da maneira como
% esta implementada, a função pode receber qualquer número de dimensões, de
% sde que a procura seja feita para uma mistura com 2 classes.
%(Duda, Hart & Stock, p. 525, eq. 24, 25, 26,27)
%
% INPUT:
% "dif_byte_no_noise": ex: differences in the fractions of (1)vegetation,
%(2)soil, (3)shade
%
%                in byte format (0-255) (zero difference at 127.5)
%                format: ERDAS 7.4 (transposed of format as in Duda)
% "M, S, P": initial guesses for mean vector, covariance matrices, a priori
%probabilities
%26/03/2009
%-----
%
% start iterative procedure
%
iter=0;
MM1=[M1];
MM2=[M2];
SS1=[S1];
SS2=[S2];
PP=[P];
while iter < max_iter
    iter=iter+1;
    %
    % estimate a posteriori probability (Duda, Hart & Stock p. 526, eq. 27)
    %
    a1 = 1/sqrt(det(S1));    %|Êi|^-1/2
    b1 = inv(S1);           % Êi^-1
    a2 = 1/sqrt(det(S2));    %|Êj|^-1/2
    b2 = inv(S2);           % Êj^-1
    aux_ones = ones(size(dif_byte_no_noise,1),1);
    np=size(dif_byte_no_noise,1);    %number of pixels in the image
    %
    nfr=size(dif_byte_no_noise,2);    % number of fractions in the image
    for i=1:nfr
        m1{i} = M1(i)*aux_ones;% i=1 vector with mean M1 (change) for fraction 1
        end

        for i=1:nfr
            m2{i} = M2(i)*aux_ones;% i=1 vector with mean M2 (no change) for fr 1
            end

            for i=1:nfr
                sample{i} = dif_byte_no_noise(:,i);    % for i=1, changes by pixel at fr1
                end

                for i=1:nfr
                    m1{i} = M1(i)*aux_ones;% i=1 vector with mean M1 (change) for fraction 1
                    end

```

```

    for i=1:nfr
m1{i} = M1(i)*aux_ones;% i=1 vector with mean M1 (change) for fraction 1
    end

    for i=1:nfr
m2{i} = M2(i)*aux_ones;% i=1 vector with mean M2 (no change) for fr 1
    end

    for i=1:nfr
sample{i} = dif_byte_no_noise(:,i); % for i=1, changes by pixel at fr1
    end

    % for class 1, change:

    for i=1:nfr
        for j=1:nfr
b1_{i,j} = b1(i,j)*aux_ones; % terms of inv(S1)= | b1_1_1 b1_1_2 |
        end % | b1_2_1 b1_2_2 |
    end %-->ex 2 frações.
%
    for i=1:nfr
        for j=1:nfr
aux1{i,j}= (sample{j}-m1{j})*b1_{j,i}; % (xk - Mi)' * Êi^-1
        end
    end

aux2=cell2mat(aux1); % transforma a celula p/ uma mat para poder somar
aux3=sum(aux2,2); % soma os termos de mesma linha das colunas de veg
%, solo, sombra para completar a operação acima.
    for i=1:nfr
aux4{i}=aux3(1+np*(i-1):i*np); % refaz a celula
    end

    for i=1:nfr
aux5{i}= aux4{i}.*(sample{i}-m1{i}); % ((xk - Mi)' * Êi^-1) * (xk - Mi)
    end
aux5=cell2mat(aux5);% transforma a celula para uma mat para poder somar
aux7=sum(aux5,2)% soma os termos de mesma linha para completar a
%operação acima

% for class 2, no change:

    for i=1:nfr
        for j=1:nfr
b2_{i,j} = b2(i,j)*aux_ones;
        end
    end
%
    for i=1:nfr
        for j=1:nfr
aux8{i,j}= (sample{j}-m2{j})*b2_{j,i};
        end
    end

aux9=cell2mat(aux8);
aux10=sum(aux9,2);

```

```

    for i=1:nfr
    aux11{i}=aux10(1+np*(i-1):i*np);
    end

    for i=1:nfr
    aux12{i}= aux11{i}.*(sample{i}-m2{i});
    end
    aux12=cell2mat(aux12);
    aux13=sum(aux12,2);

num_1 = a1*exp(-0.5*aux7)*P(1);
num_2 = a2*exp(-0.5*aux13)*P(2);
den = num_1 + num_2;
a_posteriori_1=num_1./den;
a_posteriori_2=num_2./den;
%
% update parameters (Duda, Hart & Stock, p. 525, eq. 24, 25, 26)
%
factor_1_1 = sum(a_posteriori_1);
factor_1_2 = sum(a_posteriori_2);
%
    for i=1:nfr
    a_pos_1(:,i)=a_posteriori_1;
    a_pos_2(:,i)=a_posteriori_2;
    end
    factor_2_1 = sum(a_pos_1.*dif_byte_no_noise);
    factor_2_2 = sum(a_pos_2.*dif_byte_no_noise);
    %
    m_1_1 = M1(1)*ones(size(dif_byte_no_noise,1),1);
    m_1_2 = M1(2)*ones(size(dif_byte_no_noise,1),1);
    %
    for i=1:nfr
    dif1{i} = (sample{i}-m1{i});
    end
    %
    for i=1:nfr
    for j=1:nfr
    factor31(i,j) = sum(a_posteriori_1.*(dif1{i}.*dif1{j}));
    end
    end
    %
    m_2_1 = M2(1)*ones(size(dif_byte_no_noise,1),1);
    m_2_2 = M2(2)*ones(size(dif_byte_no_noise,1),1);
    %
    for i=1:nfr
    dif2{i} = (sample{i}-m2{i});
    end
    %
    for i=1:nfr
    for j=1:nfr
    factor32(i,j) = sum(a_posteriori_2.*(dif2{i}.*dif2{j}));
    end
    end
end

```

```

P(1) = (1/np)*factor_1_1;
P(2) = (1/np)*factor_1_2;
%
M1 = factor_2_1/factor_1_1;
M2 = factor_2_2/factor_1_2;
%
S1 = factor31/factor_1_1;
S2 = factor32/factor_1_2;
%
%Curvas de convergência:
%
MM1=[MM1;M1];
MM2=[MM2;M2];
SS1=[SS1 S1];
SS2=[SS2 S2];
PP=[PP;P];
%
clear aux*
end

```

#### 4) Função para classificação por um suporte Bayesiano seguindo uma lógica *Fuzzy*

```

function [img_change,img_no_change] = fuzzy_bayes_exp_ultimo...
(dif_byte_no_noise,M1,S1,M2,S2,P)

%-----
% Esta função aplica conceitos Fuzzy para detectar mudanças
%Junho/2009
%-----

%
% INPUT:
%
siz=size(dif_byte_no_noise,1);
img_change=[];
img_no_change=[];

a1 = 1/sqrt(det(S1));    %|Êi|^(-1/2)
b1 = inv(S1);           % Êi^(-1)
a2 = 1/sqrt(det(S2));    %|Êj|^(-1/2)
b2 = inv(S2);           % Êj^(-1)
aux_ones = ones(size(dif_byte_no_noise,1),1);
np=size(dif_byte_no_noise,1);    %number of pixels in the image
%
nfr=size(dif_byte_no_noise,2);    % number of fractions in the image

    for i=1:nfr
m1{i} = M1(i)*aux_ones;        % i=1 vector with mean M1 (change)
%for fraction 1
    end

```



```

    for i=1:nfr
m2{i} = M2(i)*aux_ones;      % i=1 vector with mean M2 (no change)
%for fraction 1
    end

    for i=1:nfr
sample{i} = dif_byte_no_noise(:,i); % for i=1, changes by pixel
%at fraction 1
    end

    % for class 1, change:

    for i=1:nfr
        for j=1:nfr
b1_{i,j} = b1(i,j)*aux_ones; % terms of inv(S1)= | b1_1_1  b1_1_2 |
        end                                     % | b1_2_1  b1_2_2 |
    end                                         %-->ex 2 frações.
%
    for i=1:nfr
        for j=1:nfr
aux1{i,j}= (sample{j}-m1{j})*b1_{j,i}; % (xk - Mi)' * Êi^-1
        end
    end

    end

aux2=cell2mat(aux1); % transforma a celula para uma matriz para poder
%somar
aux3=sum(aux2,2); % soma os termos de mesma linha das colunas de veg
%, solo, sombra para completar a operação acima.
    for i=1:nfr
aux4{i}=aux3(1+np*(i-1):i*np); % refaz a celula
    end

    for i=1:nfr
aux5{i}= aux4{i}.*(sample{i}-m1{i}); % ((xk - Mi)' * Êi^-1) * (xk - Mi)
    end
aux5=cell2mat(aux5); % transforma a celula para uma
%matriz para poder somar
aux7=sum(aux5,2); % soma os termos de mesma
%linha para completar a operação acima

% for class 2, no change:

    for i=1:nfr
        for j=1:nfr
b2_{i,j} = b2(i,j)*aux_ones;
        end
    end
%
    for i=1:nfr
        for j=1:nfr
aux8{i,j}= (sample{j}-m2{j})*b2_{j,i};
        end
    end
end

```

```

aux9=cell2mat(aux8);
aux10=sum(aux9,2);
    for i=1:nfr
aux11{i}=aux10(1+np*(i-1):i*np);
    end

    for i=1:nfr
aux12{i}= aux11{i}.*(sample{i}-m2{i});
    end
aux12=cell2mat(aux12);
aux13=sum(aux12,2);

G1 = a1*exp(-0.5*aux7)*P(1);
G2 = a2*exp(-0.5*aux13)*P(2);

img_change = [G1./(G1+G2)];
img_no_change = [G2./(G1+G2)];

```

## 5) Função de inserção de informações de contexto espacial pelo método de relaxação proposto

```

function [fuzzy_change_new, diff] =
prob_relax_out_08_all_rapido_ultimo(imgc_e74,imgnc_e74,nlin,ncol,maxiter,thre
shold)

%-----
% this function iteratively updates the degrees of membership of pixels to
% the class "change" (Di zenzo, 1987)
%
%
% INPUT:
% "maxiter": maximum number of iterations allowed
% "imgc_e74.mat", "imgnc_e74.mat" in the ERDAS 7.4 format are the original
% in the real format [0,1]
% nlin = numb. of lines of the image % ncol = numb. of columns
% fuzzy image data produced (fuzzy_change_new) by function
% "fuzzy_bayes_june_14.m" is in the
% real format [0,1]
%08/10/2009
%-----
%
% initialize data
%
iter=0;
dif=100000;
diff=[];
rr=[];
%fuzzy_change_new_save=[];
%save fuzzy_change_new_save fuzzy_change_new_save

```

```

siz=size(imgc_e74); % Remontando a imagem change
img_out_625x625_change=[];
for k=1:siz(2)
    for i=1:nlin
img_out_625x625_change(i,:,k)=imgc_e74(((ncol*(i-1))+1):(i*ncol),k);
    end
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
siz=size(imgc_e74); % Remontando a imagem "no_change"
img_out_625x625_no_change=[];
for k=1:siz(2)
    for i=1:nlin
img_out_625x625_no_change(i,:,k)=imgnc_e74(((ncol*(i-1))+1):(i*ncol),k);
    end
end

fuzzy_change_new=img_out_625x625_change; %artifício para possibilitar o loop.
fuzzy_no_change_new=img_out_625x625_no_change;

%
% start iterative procedure
%
while(iter<maxiter)&(dif>threshold)
iter=iter+1
fuzzy_change_new_iter_ant=img_out_625x625_change; %para o calculo de dif
img_out_625x625_change=fuzzy_change_new;
img_out_625x625_no_change=fuzzy_no_change_new;

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%Projetando (em camadas) os 8 vizinhos (imgs 623 x 623, uma para cada
vizinho) em relação ao pixel central
%change
fuzzy_change_neighbor_0=img_out_625x625_change([2:(nlin-1)],[2:(ncol-1)]);
fuzzy_change_neighbor(:, :, 1) = img_out_625x625_change([1:(nlin-2)],[1:(ncol-2)]);
fuzzy_change_neighbor(:, :, 2) = img_out_625x625_change([1:(nlin-2)],[2:(ncol-1)]);
fuzzy_change_neighbor(:, :, 3) = img_out_625x625_change([1:(nlin-2)],[3:(ncol)]);
fuzzy_change_neighbor(:, :, 4) = img_out_625x625_change([2:(nlin-1)],[1:(ncol-2)]);
fuzzy_change_neighbor(:, :, 5) = img_out_625x625_change([2:(nlin-1)],[3:(ncol)]);
fuzzy_change_neighbor(:, :, 6) = img_out_625x625_change([3:(nlin)],[1:(ncol-2)]);
fuzzy_change_neighbor(:, :, 7) = img_out_625x625_change([3:(nlin)],[2:(ncol-1)]);
fuzzy_change_neighbor(:, :, 8) = img_out_625x625_change([3:(nlin)],[3:(ncol)]);

```

```

%no_change
fuzzy_no_change_neighbor_0=img_out_625x625_no_change([2:(nlin-1)],[2:(ncol-1)]);
fuzzy_no_change_neighbor(:, :, 1) = img_out_625x625_no_change([1:(nlin-2)],[1:(ncol-2)]);
fuzzy_no_change_neighbor(:, :, 2) = img_out_625x625_no_change([1:(nlin-2)],[2:(ncol-1)]);
fuzzy_no_change_neighbor(:, :, 3) = img_out_625x625_no_change([1:(nlin-2)],[3:(ncol)]);
fuzzy_no_change_neighbor(:, :, 4) = img_out_625x625_no_change([2:(nlin-1)],[1:(ncol-2)]);
fuzzy_no_change_neighbor(:, :, 5) = img_out_625x625_no_change([2:(nlin-1)],[3:(ncol)]);
fuzzy_no_change_neighbor(:, :, 6) =
img_out_625x625_no_change([3:(nlin)],[1:(ncol-2)]);
fuzzy_no_change_neighbor(:, :, 7) =
img_out_625x625_no_change([3:(nlin)],[2:(ncol-1)]);
fuzzy_no_change_neighbor(:, :, 8) =
img_out_625x625_no_change([3:(nlin)],[3:(ncol)]);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%Img_new sem as bordas:
fuzzy_change_new=fuzzy_change_neighbor_0;
fuzzy_no_change_new=fuzzy_no_change_neighbor_0;
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% estimate the compatibility coefficient ri(j,h,k)

%inicio calculo coef. Compatibilidade

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% compute the compatibility coefficients dimension r(8, nclass, nclass)
Ntotal =
size(fuzzy_no_change_neighbor_0,1)*size(fuzzy_no_change_neighbor_0,2);
%Numero total de pixels 623x623
r=zeros(8,2,2); % r(j,h,k) : j=1,2, .. ,8    h=1,2    k=1,2
for j=1:8
    r(j,1,1) =
(sum(sum(fuzzy_change_neighbor_0.*fuzzy_change_neighbor(:, :, j)))/Ntotal;
    r(j,1,2) =
(sum(sum(fuzzy_change_neighbor_0.*fuzzy_no_change_neighbor(:, :, j)))/Ntotal;
    r(j,2,1) =
(sum(sum(fuzzy_no_change_neighbor_0.*fuzzy_change_neighbor(:, :, j)))/Ntotal;
    r(j,2,2) =
(sum(sum(fuzzy_no_change_neighbor_0.*fuzzy_no_change_neighbor(:, :, j)))/Ntotal;
end
rr=[rr;r];

```

```

%fim calculo coef. Compatibilidade
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% updated estimated value for the degrees of membership in "change"
%

    for lin = 1:nlin-2      %A imagem a ser lida nao tem as bordas (tem menos
2 lin e menos 2 col).
        for col = 1:ncol-2 %

            if fuzzy_change_neighbor_0(lin,col)==0
                fuzzy_change_new(lin,col)=0;
                fuzzy_no_change_new(lin,col)=1;
            else

                % normalization factor (L)
                %
                % h=1: change
                %
                ww_change=0;
                ww_change = ww_change +...
                r(1,1,1)*fuzzy_change_neighbor(lin,col,1)+...
                r(2,1,1)*fuzzy_change_neighbor(lin,col,2)+...
                r(3,1,1)*fuzzy_change_neighbor(lin,col,3)+...
                r(4,1,1)*fuzzy_change_neighbor(lin,col,4)+...
                r(5,1,1)*fuzzy_change_neighbor(lin,col,5)+...
                r(6,1,1)*fuzzy_change_neighbor(lin,col,6)+...
                r(7,1,1)*fuzzy_change_neighbor(lin,col,7)+...
                r(8,1,1)*fuzzy_change_neighbor(lin,col,8)+...
                r(1,1,2)*fuzzy_no_change_neighbor(lin,col,1)+...
                r(2,1,2)*fuzzy_no_change_neighbor(lin,col,2)+...
                r(3,1,2)*fuzzy_no_change_neighbor(lin,col,3)+...
                r(4,1,2)*fuzzy_no_change_neighbor(lin,col,4)+...
                r(5,1,2)*fuzzy_no_change_neighbor(lin,col,5)+...
                r(6,1,2)*fuzzy_no_change_neighbor(lin,col,6)+...
                r(7,1,2)*fuzzy_no_change_neighbor(lin,col,7)+...
                r(8,1,2)*fuzzy_no_change_neighbor(lin,col,8);
                %
                % h=2: no change
                %
                ww_no_change=0;
                ww_no_change=ww_no_change +...
                r(1,2,1)*fuzzy_change_neighbor(lin,col,1)+...
                r(2,2,1)*fuzzy_change_neighbor(lin,col,2)+...
                r(3,2,1)*fuzzy_change_neighbor(lin,col,3)+...
                r(4,2,1)*fuzzy_change_neighbor(lin,col,4)+...
                r(5,2,1)*fuzzy_change_neighbor(lin,col,5)+...
                r(6,2,1)*fuzzy_change_neighbor(lin,col,6)+...
                r(7,2,1)*fuzzy_change_neighbor(lin,col,7)+...
                r(8,2,1)*fuzzy_change_neighbor(lin,col,8)+...
                r(1,2,2)*fuzzy_no_change_neighbor(lin,col,1)+...
                r(2,2,2)*fuzzy_no_change_neighbor(lin,col,2)+...
                r(3,2,2)*fuzzy_no_change_neighbor(lin,col,3)+...
                r(4,2,2)*fuzzy_no_change_neighbor(lin,col,4)+...
                r(5,2,2)*fuzzy_no_change_neighbor(lin,col,5)+...
                r(6,2,2)*fuzzy_no_change_neighbor(lin,col,6)+...

```

```

        r(7,2,2)*fuzzy_no_change_neighbor(lin,col,7)+...
        r(8,2,2)*fuzzy_no_change_neighbor(lin,col,8);
        %
        L =fuzzy_change_neighbor_0(lin,col)*(1+(1/8)*ww_change) +
fuzzy_no_change_neighbor_0(lin,col)*(1+(1/8)*ww_no_change);
        %
        % updated estimated value for the degrees of membership in
"change"
        %
        %
fuzzy_change_new(lin,col)=(1/L)*fuzzy_change_neighbor_0(lin,col)*(1+
ww_change/8);
        end
        end
        end
        %Recolocando as bordas originais da imagem:
img_out_625x625_change(2:nlin-1,2:ncol-1)=fuzzy_change_new;
fuzzy_change_new=img_out_625x625_change;
%computing no_change:
fuzzy_no_change_new=1-fuzzy_change_new;
%
% check for convergence e criar curva de convergencia (diff)
%
dif=mean(mean(abs(fuzzy_change_new-fuzzy_change_new_iter_ant)));
diff=[diff;dif];
%
%criar uma curva de pertinencia à img referencia (ou sintetica)
%
% Habilitar abaixo e entrar com a imagem refere na função
% d(iter)=sum(abs(fuzzy_change_new*255-refere));
%
%Procedimento de arquivo no disco rígido: Nessecita escolher e habilitar:
%tirar os
%'%' das linhas que quer usar.
%
%Este continua aumentando o espaço na memória:
%fuzzy_change_new_all(:, :, iter)=fuzzy_change_new;
%
%Este tambem:
%load fuzzy_change_new_save
%eval(['fuzzy_change_new_' num2str(iter) ' = fuzzy_change_new;']);
%fuzzy_change_new_save(:, :, iter)=fuzzy_change_new;
%save fuzzy_change_new_save fuzzy_change_new_save % Salva todas as
%imagens geradas no arquivo fuzzy_change_new.mat
%
%Este salva arquivo por arquivo no disco rígido da forma
%'fuzzy_change_new_000'
%tmpl='fuzzy_change_new_%3.3d.tif'; % <- file name template
%fnam=sprintf(tmpl,iter); % <- file name depending on I
%imwrite(fuzzy_change_new,fnam,'tif'); % <- save it in a .tif file
%ou
%save(fnam,'fuzzy_change_new'); % <- save it in a .mat file

end

```

**6) Função usada para reorganizar a imagem do formato Erdas 7.4 para o formato retangular.**

```
function img_out=seeimg(img_e74,lin,col);

%-----
%This function sets up any erdas74 formatted image for visualization.
%The range of values byte (0->255) keeps the same.
%
%img_erdas74 ---> is the image to be placed normally again
%lin--> number of lines of the image   col---> numb of columns of the image
%img_out ---> is the output image file
%15/03/2009
%-----

siz=size(img_e74);
double(img_e74);
img_out=[];
img_out_byte=[];
for k=1:siz(2)
    for i=1:lin
img_out(i,:,k)=img_e74(((col*(i-1))+1):(i*col),k);
        end
    end
end
```