

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA**

TESE DE DOUTORADO

**DETECÇÃO DE MUDANÇAS A PARTIR
DE IMAGENS DE FRAÇÃO**

HÉLIO RADKE BITTENCOURT

Orientador: Prof^ª Dra. Dejanira Luderitz Saldanha

PORTO ALEGRE, SETEMBRO DE 2011.

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA**

TESE DE DOUTORADO

**DETECÇÃO DE MUDANÇAS A PARTIR
DE IMAGENS DE FRAÇÃO**

HÉLIO RADKE BITTENCOURT

Orientador: Prof^ª Dra. Dejanira Luderitz Saldanha

Banca Examinadora:

Prof. Dr. Laurindo Guasselli (POSGEA/UFRGS)
Profa. Dra. Jandyra Fachel (IM/UFRGS)
Profa. Dra. Adriane Parraga (UERGS)
Profa. Dra. Viviane Todt (UNISINOS)

Tese apresentada ao Programa de
Pós-graduação em Geografia como
requisito para obtenção do título de
Doutor em Geografia.

PORTO ALEGRE, SETEMBRO DE 2011.

CIP - Catalogação na Publicação

Bittencourt, Helio Radke
Detecção de mudanças a partir de imagens de fração /
Helio Radke Bittencourt. -- 2011.
113 f.

Orientadora: Dejanira Luderitz Saldanha.

Tese (Doutorado) -- Universidade Federal do Rio
Grande do Sul, Instituto de Geociências, Programa de
Pós-Graduação em Geografia, Porto Alegre, BR-RS, 2011.

1. Detecção de mudanças. 2. Imagens de fração. 3.
Processamento de imagens digitais. 4. Classificação
rígida. 5. Classificação fuzzy. I. Saldanha, Dejanira
Luderitz, orient. II. Título.

AGRADECIMENTOS

Quando iniciei o projeto de doutorado sobre detecção de mudanças, nem imaginava a quantidade de mudanças que ocorreriam, tanto no meu trabalho como na minha vida, durante esse período de aproximadamente 4,5 anos. Iniciei pensando em trabalhar com imagens de entropia e coerência; terminei com imagens de fração. Iniciei com um orientador; terminei com uma orientadora. Iniciei pensando em fazer doutorado-sanduíche na França; terminei fazendo planos para um pós-doutorado. Iniciei sem filhos; terminei pai de um menino de quase três anos. Iniciei achando que o doutorado seria o fim de uma etapa; termino com a certeza de que será o início de muitas!

Em primeiro lugar, agradeço à **Universidade Federal do Rio Grande do Sul** (UFRGS), instituição na qual desenvolvi a minha formação acadêmica de graduação, mestrado e, agora, doutorado. Fico muito feliz em fazer parte de uma universidade que tem figurado em diversos *rankings* como uma das melhores do país.

Agradeço à **Profa Jandyra Fachel** que, em 1994, me convidou para ser seu bolsista de iniciação científica, inserindo-me assim na vida acadêmica de pesquisa. As atividades que realizamos e, em especial, as assessorias estatísticas, possibilitaram-me transitar por diferentes áreas do conhecimento, ajudando-me na opção pelo curso de Mestrado em Sensoriamento Remoto, o qual me trouxe para a área de Geociências.

Agradeço ao **Prof. Robin Thomas Clarke**, meu orientador de Mestrado, que confiou em mim e incentivou-me a seguir adiante no trabalho, ajudando-me nas publicações derivadas da dissertação e no exame de qualificação de doutorado. Estendo o agradecimento ao **Prof. Vitor Haertel**, que participou ativamente da minha formação, sendo o meu orientador nos primeiros anos de doutorado e coautor de trabalhos que foram apresentados no Brasil e no Exterior.

Agradeço muito à **Profa Dejanira Saldanha**, que aceitou me orientar a partir dos “40 minutos do 2º tempo” e, mesmo estando em meio a muitos projetos e orientações, deu-me a força necessária para que eu não desistisse.

Agradeço aos professores **Claudio Jung** (UFRGS), **Vinícius Licks** (PUCRS) e **Fabício Ourique** (UNIPAMPA), a quem recorri em momentos de dúvidas no Matlab[®] ou em tópicos específicos de Processamento de Imagens, e ao ex-colega **Daniel Zanotta**, hoje doutorando no INPE, com quem aprendi muito, estudando e debatendo sobre *change*

detection. Foi ele quem escreveu a rotina para fracionamento de imagens utilizada nesta tese. Obrigado, Daniel!

Agradeço ao **Instituto Nacional de Pesquisas Espaciais** (INPE) pela concessão das imagens Landsat-TM e por ter me proporcionado contato com alguns dos principais pesquisadores da área durante os Simpósios Brasileiros de Sensoriamento Remoto (SBSRs). O curso sobre *change detection* com o Prof. Lorenzo Bruzzone (amplamente citado nesta tese) no SBSR de 2009 foi importantíssimo para mim.

Agradeço aos meus colegas da **Pontifícia Universidade Católica do Rio Grande do Sul** (PUCRS), instituição na qual trabalho desde 2002 e, em regime de dedicação exclusiva, desde 2005, por terem me incentivado a seguir no doutorado. Com eles compartilhei ansiedades e preocupações, além de questões técnicas. Agradeço aos colegas da Faculdade de Matemática, professores **Lori Viali**, **João Feliz** e **Augusto Cardona**; aos colegas da Assessoria de Planejamento e Marketing, professores **Alziro Rodrigues** e **Alam Casartelli**; aos técnicos administrativos **André Selbach**, **Josilene Rocha** e **Beatris Moura Maurmann** e ao duplamente colega (UFRGS e PUCRS) **Thiago Bazzan**, que preparou dois conjuntos de imagens utilizados nos experimentos desta tese.

Agradeço aos familiares e, em especial, à minha esposa **Suzel** e ao meu filho **Max**, pela paciência. Durante o doutorado, deixei de acompanhá-los em muitos e muitos eventos. Estendo o agradecimento às vovós **Claudete** e **Edite**, que me salvaram inúmeras vezes, cuidando do neto, e a prima **Adilse** pela revisão ortográfica.

Acima de tudo, agradeço a **Deus** pela dádiva da vida e por ter concedido saúde, não só a mim, mas também às pessoas que me cercam.

RESUMO

A detecção de mudanças na superfície terrestre é o principal objetivo em aplicações de sensoriamento remoto multitemporal. Sabe-se que imagens adquiridas em datas distintas tendem a ser altamente influenciadas por problemas radiométricos e de registro. Utilizando imagens de fração, obtidas a partir do modelo linear de mistura espectral (MLME), problemas radiométricos podem ser minimizados e a interpretação dos tipos de mudança na superfície terrestre é facilitada, pois as frações têm um significado físico direto. Além disso, interpretações ao nível de subpixel são possíveis. Esta tese propõe três algoritmos – *rígido*, *suave* e *fuzzy* – para a detecção de mudanças entre um par de imagens de fração, gerando mapas de mudança como produtos finais. As propostas requerem a suposição de normalidade multivariada para as diferenças de fração e necessitam de pouca intervenção por parte do analista. A proposta *rígida* cria mapas de mudança binários seguindo a mesma metodologia de um teste de hipóteses, baseando-se no fato de que os contornos de densidade constante na distribuição normal multivariada são definidos por valores da distribuição qui-quadrado, de acordo com a escolha do nível de confiança. O classificador *suave* permite gerar estimativas da probabilidade do pixel pertencer à classe de mudança, a partir de um modelo de regressão logística. Essas probabilidades são usadas para criar um mapa de probabilidades de mudança. A abordagem *fuzzy* é aquela que melhor se adapta ao conceito de pixel mistura, visto que as mudanças no uso e cobertura do solo podem ocorrer em nível de subpixel. Com base nisso, mapas dos graus de pertinência à classe de mudança foram criados. Outras ferramentas matemáticas e estatísticas foram utilizadas, tais como operações morfológicas, curvas ROC e algoritmos de *clustering*. As três propostas foram testadas utilizando-se imagens sintéticas e reais (Landsat-TM) e avaliadas qualitativa e quantitativamente. Os resultados indicam a viabilidade da utilização de imagens de fração em estudos de detecção de mudanças por meio dos algoritmos propostos.

Palavras-chave: Detecção de mudanças, Imagens de fração, Processamento Digital de Imagens, Classificação rígida, Classificação fuzzy.

ABSTRACT

Land cover change detection is a major goal in multitemporal remote sensing applications. It is well known that images acquired on different dates tend to be highly influenced by radiometric differences and registration problems. Using fraction images, obtained from the linear model of spectral mixing (LMSM), radiometric problems can be minimized and the interpretation of changes in land cover is facilitated because the fractions have a physical meaning. Furthermore, interpretations at the subpixel level are possible. This thesis presents three algorithms – hard, soft and fuzzy – for detecting changes between a pair of fraction images. The algorithms require multivariate normality for the differences among fractions and very little intervention by the analyst. The hard algorithm creates binary change maps following the same methodology of hypothesis testing, based on the fact that the contours of constant density are defined by chi-square values, according to the choice of the probability level. The soft one allows for the generation of estimates of the probability of each pixel belonging to the change class by using a logistic regression model. These probabilities are used to create a map of change probabilities. The fuzzy approach is the one that best fits the concept behind the fraction images because the changes in land cover can occur at a subpixel level. Based on these algorithms, maps of membership degrees were created. Other mathematical and statistical techniques were also used, such as morphological operations, ROC curves and a clustering algorithm. The algorithms were tested using synthetic and real images (Landsat-TM) and the results were analyzed qualitatively and quantitatively. The results indicate that fraction images can be used in change detection studies by using the proposed algorithms.

Keywords: Change detection, Fraction Images, Digital Image Processing, Hard classification, Soft classification, Fuzzy classification.

SUMÁRIO

1. INTRODUÇÃO	1
1.1 TEMA E OBJETIVOS	3
1.2 ESTRUTURA DA TESE	4
2. REVISÃO BIBLIOGRÁFICA	6
2.1 PRINCIPAIS TÉCNICAS PARA DETECÇÃO DE MUDANÇAS	8
2.2 TÉCNICAS DE DETECÇÃO DE MUDANÇAS RECENTES	11
2.3 O CONTEXTO ESPACIAL NA DETECÇÃO DE MUDANÇAS	13
2.4. O MODELO LINEAR DE MISTURA ESPECTRAL E A GERAÇÃO DE IMAGENS DE FRAÇÃO	15
2.5. O MODELO LINEAR DE MISTURA ESPECTRAL (MLME) EM ESTUDOS DE DETECÇÃO DE MUDANÇAS	16
2.6 PRÉ-PROCESSAMENTO	18
2.7 ESTUDOS COMPARATIVOS	20
2.8 MEDIDAS DE AVALIAÇÃO DE DESEMPENHO	21
3. MÉTODOS	26
3.1 MODELO LINEAR DE MISTURA ESPECTRAL (MLME)	26
3.2 MÉTODOS DE CLASSIFICAÇÃO RÍGIDA, SUAVE E FUZZY	29
3.2.1 Probabilidade versus Graus de Pertinência	32
3.3 PROPOSTA DE UM CLASSIFICADOR RÍGIDO PARA DETECÇÃO DE MUDANÇAS	32
3.3.1 Introdução de informação de contexto: operações morfológicas	36
3.3.2 Classes de Mudanças	38
3.3.3 Resumo da proposta rígida	40
3.4 PROPOSTA DE UM CLASSIFICADOR SUAVE PARA DETECÇÃO DE MUDANÇAS	42
3.5 PROPOSTA DE UM CLASSIFICADOR <i>FUZZY</i> PARA DETECÇÃO DE MUDANÇAS	45
3.5.1 Fuzzificação via Distância de Mahalanobis	47
3.6 RECURSOS COMPUTACIONAIS	51
4. EXPERIMENTOS	53
4.1 EXPERIMENTOS COM IMAGENS SINTÉTICAS	54
4.1.1 Experimento S1	54
4.1.2 Experimento S2	65

4.2 EXPERIMENTOS COM IMAGENS LANDSAT-TM	72
4.2.1 Experimento R1.....	72
4.2.2 Experimento R2.....	79
4.2.3 Experimento R3.....	85
4.3 ANÁLISE COMPARATIVA	90
5. CONCLUSÃO	97
5.1 CONTRIBUIÇÕES DESTA TESE	98
5.2 TRABALHOS FUTUROS	99
REFERÊNCIAS	100

LISTA DE FIGURAS

Figura 1 – Representação da função densidade dos contadores digitais dos pixels da imagem de diferença com a definição de um limiar (τ) entre as classes mudança e não-mudança	8
Figura 2 – Definições formais e localização das regiões de mudanças e não-mudança.....	12
Figura 3 – Representação dos pixels no espaço de coordenadas polares usando a técnica de Análise do vetor de mudanças.....	12
Figura 4 – Exemplo de segmento de imagem Landsat-TM, (a) composição colorida 7-4-1 (RGB). Conjunto de imagens de fração referentes à (b) vegetação, (c) solo exposto e (c) água.....	16
Figura 5 – O problema de registro entre duas imagens de uma mesma cena	19
Figura 6 – Exemplo de curva ROC para avaliação de desempenho de cinco classificadores.....	24
Figura 7 – Exemplo ilustrativo do processo de geração de imagens sintéticas.....	25
Figura 8 – Exemplo ilustrativo da utilização de diagrama de dispersão para seleção de pixels candidatos a <i>endmembers</i>	28
Figura 9 – Etapas básicas para a geração de uma imagem de fração a partir de uma imagem espectral.....	28
Figura 10 – Exemplo da geração de imagens de fração a partir de uma imagem Landsat-TM	29
Figura 11 – Representação gráfica da função densidade de probabilidade de uma variável X que segue distribuição Qui-quadrado com $\nu=5$	34
Figura 12 – Exemplo de operacionalização do conceito de detecção de mudanças proposto para $\nu=2$. A aceitação de H_0 é associada à classe de não-mudança.	35
Figura 13 – Representação da partição do espaço de diferenças de fração para o caso bidimensional ($\nu=2$)	39
Figura 14 – Fluxograma do classificador rígido para detecção de mudanças.....	41
Figura 15 – Exemplo da probabilidade de pertencer à classe ω_c estimada pelo modelo de regressão logística como função de uma única componente d_i da imagem de diferenças de fração.....	43
Figura 16 - Fluxograma do classificador suave para detecção de mudanças aplicando regressão logística.....	44
Figura 17 – Funções densidade normais multivariadas representativas das classes ω_c e ω_{nc}	47
Figura 18 – Representação gráfica do cálculo de w_c – grau de pertinência à classe ω_c – por meio da função de distribuição acumulada do modelo Qui-quadrado.....	48
Figura 19 – Função de distribuição acumulada do modelo Qui-quadrado para três diferentes graus de liberdade (ν).....	49
Figura 20 – Valores de $w_c^{(4)}$ e $w_c^{(8)}$ como função de w_c em situações nas quais todos os graus de pertinência da vizinhança são iguais.....	50
Figura 21 – Fluxograma do classificador <i>fuzzy</i> para detecção de mudanças a partir da distância de Mahalanobis	51
Figura 22 – Cena Landsat-TM correspondente à órbita-ponto 220/81 e detalhe do recorte efetivamente utilizado no experimento S1	54
Figura 23 – Conjunto de imagens de diferença de fração do experimento S1 contaminadas com três níveis de ruído gaussiano (SNR=40dB, 20dB e 10dB).	55

Figura 24 – Localização das alterações de paisagem inseridas para geração da imagem sintética do experimento S1: mapa de referência.....	56
Figura 25 – Mapas de mudança resultantes da proposta rígida com $(1-\infty)=95\%$: (a) sem filtragem, (b) com filtragem morfológica utilizando os elementos B_4 e (c) B_8	57
Figura 26 – Mapas de mudança resultantes da proposta rígida com $(1-\infty)=99,74\%$: (a) sem filtragem, (b) com filtragem morfológica utilizando os elementos B_4 e (c) B_8	57
Figura 27 – Curvas ROC para diferentes valores de SNR (sem e com filtragem morfológica), e níveis de confiança (90, 95, 99 e 99,74%)	59
Figura 28 – Variação do coeficiente <i>kappa</i> em função do SNR (sem e com filtragem morfológica) para quatro diferentes níveis de confiança (90, 95, 99 e 99,74%).....	59
Figura 29 – Mapa temático construído a partir da análise de agrupamento para identificação dos tipos de mudança e gráfico de dispersão entre as diferenças de fração dos componentes vegetação e solo exposto – Experimento S1	60
Figura 30 – Mapas da probabilidade de pertencer à classe ω_c para diferentes níveis de confiança e valores de SNR.....	62
Figura 31 – Histograma da probabilidade de pertencer à classe ω_c para $(1-\infty)=95\%$ e SNR=20dB	62
Figura 32 – Mapas dos graus de pertinência à classe ω_c utilizando dois esquemas de vizinhança e sob diferentes valores de SNR	63
Figura 33 – Histograma dos graus de pertinência dos mapas CM_{fuzzy} utilizando dois esquemas de vizinhança – Experimento S1 com SNR=10 e 20dB.	64
Figura 34 – Cena Landsat-TM correspondente à órbita-ponto 220/81 e detalhe do recorte efetivamente utilizado no experimento S2	65
Figura 35 – Imagens de fração utilizadas no experimento S2: vegetação, solo exposto e água	65
Figura 36 – Imagens de diferenças de fração contaminada com ruído (SNR=10dB) e mapa de referência – Experimento S2.....	66
Figura 37 – Mapas de mudança binários resultantes da proposta rígida com $(1-\alpha)=90\%$: sem filtragem e com filtragem morfológica utilizando os elementos B_4 e B_8	67
Figura 38 – Curvas ROC para diferentes valores de SNR (sem e com filtragem morfológica), e níveis de confiança (90, 95, 99 e 99,74%) – Experimento S2.....	68
Figura 39 – Mapa temático construído a partir da análise de agrupamento – Experimento S2	69
Figura 40 – Mapas da probabilidade de pertencer à classe ω_c para diferentes nível de confiança de 90% e valores de SNR ≤ 15 dB	70
Figura 41 – Mapas dos graus de pertinência à classe ω_c utilizando dois esquemas de vizinhança e sob diferentes valores de SNR	71
Figura 42 – Cenas Landsat-TM correspondentes à órbita-ponto 220/81 e detalhes dos recortes efetivamente utilizados no experimento R1	72
Figura 43 – Imagens de fração considerando três <i>endmembers</i> – vegetação, solo exposto e água – para as duas imagens do experimento R1. Acima o recorte da cena em t_1 e abaixo em t_2	73
Figura 44 – Mapas de mudança resultantes da proposta rígida no experimento R1 com quatro diferentes níveis de confiança, (a) sem filtragem, (b) com filtragem morfológica utilizando o elemento B_4 e (c) com filtragem morfológica utilizando o elemento B_8	74
Figura 45 – Gráfico de dispersão entre as diferenças de fração – componentes vegetação, solo exposto e água – Experimento R1	75
Figura 46 - Mapa temático construído a partir da análise de agrupamento para identificação dos tipos de mudança – Experimento R1	75

Figura 47 – Mapas da probabilidade de pertencer à classe ω_c para diferentes níveis de confiança	77
Figura 48 – Superfície estimada por regressão logística utilizada para estimação das probabilidades de pertencer à classe de mudanças $(1-\alpha)=95\%$	77
Figura 49 – Mapas dos graus de pertinência à classe ω_c utilizando dois esquemas de vizinhança.....	78
Figura 50 – Histograma dos graus de pertinência dos mapas CM_{fuzzy} utilizando dois esquemas de vizinhança	78
Figura 51 – Localização da área de estudo	79
Figura 52 – Imagens Landsat-TM da área de estudo em 1994 e 1996 respectivamente. Composições coloridas em cores naturais.....	79
Figura 53 – Imagens de fração considerando três <i>endmembers</i> – vegetação, solo exposto e sombra – para as duas imagens do experimento R2. Acima o recorte da cena em t_1 e abaixo em t_2	80
Figura 54 – Mapas de mudança resultantes da proposta rígida no experimento R2 com quatro diferentes níveis de confiança, sem filtragem e com filtragem morfológica utilizando os elementos B_4 e B_8	81
Figura 55 - Mapa temático construído a partir da análise de agrupamento para identificação dos tipos de mudança – Experimento R2.....	82
Figura 56 – Mapas da probabilidade de pertencer à classe ω_c para diferentes níveis de confiança	83
Figura 57 – Mapas dos graus de pertinência à classe ω_c utilizando dois esquemas de vizinhança.....	84
Figura 58 – Histograma dos graus de pertinência dos mapas CM_{fuzzy} utilizando dois esquemas de vizinhança	84
Figura 59 – Cenas Landsat-TM correspondentes à órbita-ponto 220/78 e 79 e detalhes dos recortes efetivamente utilizados no experimento R3	85
Figura 60 – Imagens de fração considerando quatro <i>endmembers</i> – vegetação, solo exposto, água e sombra – para as duas imagens do experimento R3. Acima o recorte da cena em t_1 e abaixo em t_2	86
Figura 61 – Mapas de mudança resultantes da proposta rígida no experimento R3 com quatro diferentes níveis de confiança, (a) sem filtragem, (b) com filtragem morfológica utilizando o elemento B_4 e (c) com filtragem morfológica utilizando o elemento B_8	87
Figura 62 - Mapa temático construído a partir da análise de agrupamento para identificação dos tipos de mudança – Experimento R3	87
Figura 63– Variação das estimativas dos parâmetros do modelo de regressão logística em função do nível de confiança adotado – Experimento R3.....	89
Figura 64– Mapas da probabilidade de pertencer à classe ω_c para diferentes níveis de confiança	89
Figura 65 – Mapas dos graus de pertinência à classe ω_c utilizando dois esquemas de vizinhança.....	90
Figura 66 – <i>Boxplots</i> dos graus de pertinência gerados pelo classificador <i>fuzzy</i> no experimento S1 sob dois níveis de SNR conforme o mapa de referência ($\omega_c=1$ e $\omega_{nc}=0$)...	92
Figura 67 – <i>Boxplots</i> das probabilidades e graus de pertinência <i>fuzzy</i> de acordo com o resultado da classificação rígida – Experimento R1	95
Figura 68 – <i>Boxplots</i> das probabilidades e graus de pertinência <i>fuzzy</i> de acordo com o resultado da classificação rígida – Experimento R2.....	95
Figura 69 – <i>Boxplots</i> das probabilidades e graus de pertinência <i>fuzzy</i> de acordo com o resultado da classificação rígida – Experimento R3	96

LISTA DE TABELAS E QUADROS

Tabela 1 – Matriz de confusão para avaliação de algoritmos de detecção de mudanças binários.....	22
Tabela 2 - Indicadores quantitativos de desempenho do classificador (sem e com filtragem morfológica) sob diferentes valores de SNR e com diferentes níveis de confiança (1- α). ..	58
Tabela 3 – Estimativas para o modelo de regressão logística utilizado na classificação suave para diferentes níveis de confiança e SNR.....	61
Tabela 4 - Indicadores quantitativos de desempenho do classificador (sem e com filtragem morfológica) sob diferentes valores de SNR e com diferentes níveis de confiança (1- α). ..	67
Tabela 5 – Estimativas para o modelo de regressão logística utilizado na classificação suave para diferentes níveis de confiança e SNR – Experimento S2	70
Tabela 6 – Estimativas para o modelo de regressão logística utilizado no experimento R1 para classificação suave com diferentes níveis de confiança.....	76
Tabela 7 – Estimativas para o modelo de regressão logística utilizado no experimento R2 para classificação suave com diferentes níveis de confiança.....	83
Tabela 8 – Estimativas para o modelo de regressão logística utilizado no experimento R3 para classificação suave com diferentes níveis de confiança.....	88
Tabela 9 – Valores do Erro Quadrático Médio (MSE) para os mapas de mudança gerados pelos classificadores rígido e suave no experimento S1 ($\times 10^{-2}$)	91
Tabela 10 – Valores do Erro Quadrático Médio (MSE) para os mapas de mudança gerados pelos classificadores rígido, suave e <i>fuzzy</i> no experimento S2 ($\times 10^{-2}$).....	93
Tabela 11 – Coeficientes de correlação entre as probabilidades estimadas pelo algoritmo de classificação suave e os graus de pertinência <i>fuzzy</i> $w^{(4)}$ e $w^{(8)}$ nos experimentos R1-R3	94
Quadro 1 – Resumo das principais técnicas de detecção de mudanças e seus tipos	10
Quadro 2 – Exemplo de funções de pertencimento utilizadas no processo de <i>fuzzificação</i>	31
Quadro 3 – Características das imagens utilizadas nos experimentos.....	54

LISTA DE ABREVIATURAS E SIGLAS

ACP	Análise de Componentes Principais
CATMOD	<i>Categorical data Modeling</i>
CBERS	<i>China Brazil Earth Resources Satellite</i>
CCD	<i>Charge-Coupled Device</i>
CM	<i>Change Map</i>
CVA	<i>Change Vector Analysis</i>
DR	<i>Detection Rate</i>
EM	<i>Expectation Maximization</i>
ENVI	<i>Environment for Visualizing Images</i>
ERDAS	<i>Earth Resources Data Analysis System</i>
ESA	<i>European Space Agency</i>
FA	<i>False-Alarm</i>
IFOV	<i>Instantaneous Field Of View</i>
INPE	Instituto Nacional de Pesquisas Espaciais
Landsat	<i>Land Satellite</i>
MATLAB	<i>Matrix Laboratory</i>
MLME	Modelo Linear de Mistura Espectral
MNRFIT	<i>Multinomial logistic Regression</i>
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
MRF	<i>Markov Random Fields</i>
MSE	<i>Mean Square Error</i>
MSS	<i>Multispectral scanner</i>
NASA	<i>National Aeronautics and Space Administration</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
PSNR	<i>Peak Signal-to-Noise Ratio</i>
RAM	<i>Random Access Memory</i>
ROC	<i>Receiver Operating Characteristic</i>
SAS	<i>Statistical Analysis System</i>
SIG	Sistemas de Informação Geográfica
SNR	<i>Signal-to-Noise Ratio</i>
SPOT	<i>Système Probatoire pour l'Observation de la Terre</i>
SVM	<i>Support Vector Machine</i>
TM	<i>Thematic Mapper</i>

LISTA DE SÍMBOLOS

N	Número de linhas da imagem multiespectral
M	Número de colunas da imagem multiespectral
p	Número de bandas espectrais da imagem multiespectral
\mathbf{X}_t	Matriz que representa a imagem multiespectral no instante t com dimensionalidade $NM \times p$ (formato Raster)
$\mathbf{x}_i(i,j)$	Vetor da resposta espectral correspondente ao pixel com coordenadas (i,j) no instante t . $i=1,2,\dots,N$; $j=1,2,\dots,M$; $t=1$ ou 2
m	Número de <i>endmembers</i> considerados para geração das imagens de fração
\mathbf{R}	Matriz $p \times m$ que relaciona a resposta espectral dos m <i>endmembers</i>
ν	Dimensionalidade do problema: número <i>endmembers</i> menos um ($\nu = m-1$)
\mathbf{F}_t	Matriz que representa uma imagem de fração no instante t com dimensionalidade $NM \times m$
$\mathbf{f}_i(i,j)$	Vetor que representa as frações do pixel com coordenadas (i,j) no instante t ocupada pelos m <i>endmembers</i> . $i=1,2,\dots,N$; $j=1,2,\dots,M$
\mathbf{D}	Matriz que representa a imagem de diferenças de fração (e.g. $\mathbf{D}=\mathbf{F}_2-\mathbf{F}_1$) com dimensionalidade $NM \times \nu$
$\mathbf{d}(i,j)$	Vetor de diferenças ν -dimensional correspondente ao pixel com coordenadas (i,j) $i=1,2,\dots,N$; $j=1,2,\dots,M$
ω_c e ω_{nc}	Classes de mudança e não-mudança que formam o conjunto considerado pelo classificador rígido binário $\Omega = \{\omega_c, \omega_{nc}\}$
ω_{ci}	Sub-classes associadas à ω_c . $i=1,2, \dots, K$
$\boldsymbol{\mu}_d$ e $\boldsymbol{\Sigma}$	Vetor média e matriz covariância da imagem de diferenças. Parâmetros da distribuição normal multivariada
α e $(1-\alpha)$	Nível de significância e nível de confiança, respectivamente.
β_0 e $\boldsymbol{\beta}$	Parâmetros do modelo de regressão logística.
$P(\omega_c \mathbf{d})$	Probabilidade de um vetor \mathbf{d} pertencer a classe de mudança.
\mathbf{B}_4 e \mathbf{B}_8	Elementos estruturantes para fins de filtragem morfológica.
$w_c^{(4)}$ e $w_c^{(8)}$	Graus de pertinência à classe ω_c para os esquemas com 4 e 8 vizinhos
\mathbf{CM} e \mathbf{CM}'	Mapas binários de mudança gerados pelo classificador rígido, sem e com filtragem morfológica, respectivamente.
\mathbf{CMP}	Mapa da probabilidade de pertencer à classe ω_c . Produto final do classificador suave.
\mathbf{CM}_{fuzzy}	Mapa dos graus de pertinência à classe ω_c . Produto final do classificador <i>fuzzy</i> .
\mathbf{CM}_{Ref}	Mapa de referência que representa regiões de mudança artificialmente inseridas ou verdade terrestre.

1. INTRODUÇÃO

Detectar mudanças em sensoriamento remoto significa identificar alterações na superfície terrestre por meio da análise de imagens da mesma cena coletadas em diferentes datas. A premissa básica da detecção de mudanças é a de que todas as alterações na cobertura terrestre deverão resultar em mudanças nos valores de radiância (SINGH, 1989) e, conseqüentemente, os sensores remotos deverão registrar tais mudanças armazenando diferentes valores de contadores digitais. Para melhor entendimento, faz-se necessário conhecer o processo de formação de uma imagem digital.

O produto típico de um sensor remoto moderno é uma imagem digital. Gonzalez, Woods e Eddins (2004) definem uma imagem digital como uma função bi-dimensional $f(x,y)$ onde x e y são coordenadas espaciais discretas e o valor de f para qualquer par de coordenadas (x,y) indica a intensidade da imagem naquele ponto. O pixel é o menor elemento da imagem, e seu tamanho está diretamente relacionado à resolução espacial do sistema sensor. A intensidade da imagem no pixel é chamada de nível de cinza ou número digital, a qual se origina da seguinte forma: os sensores remotos transformam a energia proveniente da interação entre a radiação solar e a superfície terrestre em sinais elétricos que são registrados na forma de números digitais que indicam o nível de radiância médio da área correspondente a um pixel em um determinado comprimento de onda. Em geral, um sistema sensor registra sinais em um conjunto de diferentes faixas do espectro eletromagnético, portanto em diferentes comprimentos de onda, formando, assim, o conjunto de p bandas espectrais.

Portanto, de um ponto de vista matemático, cada pixel da imagem pode ser visualizado como um vetor p -dimensional. Admitindo-se que a radiância dos alvos captada pelo sensor é influenciada por inúmeros fatores aleatórios (por exemplo, presença da atmosfera, ângulo de iluminação solar, deficiências no próprio sistema sensor), pode-se considerar o vetor de valores observados para cada pixel como uma estimativa do verdadeiro nível de radiância do(s) alvo(s) correspondente(s) àquele pixel. Assim, um componente de incerteza deve ser associado aos valores observados para cada pixel, caracterizando, então, o processamento de imagens digitais como um problema de natureza estatística.

Problemas que envolvem os diferentes tipos de classificação de imagens enquadram-se numa importante área denominada Reconhecimento de Padrões, que se ocupa da identificação, da descrição, do agrupamento e da classificação de padrões (JAIN; DUIN;

MAO, 2000). Exemplos de padrões podem ser letras de um alfabeto, árvores de uma floresta, impressões digitais ou pixels de uma imagem (DUDA; HART; STORK, 2001).

Em Reconhecimento de Padrões, o objetivo primordial é algum tipo de classificação. Os melhores reconhecedores de padrões, na maioria das situações, são os próprios seres humanos. Embora ainda não se conheça como ocorre este processo em sua plenitude, busca-se aproximar o reconhecimento automático realizado pela máquina à eficiência humana.

O reconhecimento de padrões é de fundamental importância no mundo moderno. Cada vez mais é necessária a geração de sistemas, preferencialmente automáticos, que sejam capazes de lidar com a grande quantidade de informações disponíveis (BITTENCOURT, 2001). A área de reconhecimento de padrões (*pattern recognition*) está associada ao aprendizado de máquina (*machine learning*), visão computacional (*computer vision*) e inteligência artificial (*artificial intelligence*), sendo praticamente impossível definir a atuação de cada área de forma isolada. Poderiam ser aqui incluídas, ainda, as áreas de processamento de imagem e sinais (*signal and image processing*), estatística aplicada (*applied statistics*) e redes neurais (*neural networks*).

O presente estudo pode ser enquadrado ainda numa importante área denominada Reconhecimento Estatístico de Padrões, visto que cada pixel das imagens será assumido como um vetor aleatório p -dimensional. A abordagem estatística é especialmente adequada em problemas de detecção de mudanças da superfície terrestre em imagens digitais, tendo conduzido muitas das propostas encontradas na literatura. Além do sensoriamento remoto, a detecção automática de mudanças tem provocado interesse em diferentes áreas do conhecimento, tais como: o monitoramento de câmeras de vídeo para segurança, diagnóstico médico, infraestrutura civil, entre outras. Apesar das diferentes áreas de aplicação, pesquisadores tendem a utilizar metodologias semelhantes e algoritmos em comum (RADKE et al, 2005). Dentre as aplicações de sensoriamento remoto, destacam-se o monitoramento de áreas desmatadas e queimadas, avaliação de desastres naturais, análise da expansão de áreas urbanas, acompanhamento de áreas cultivadas, etc. (BAZI; BRUZZONE; MELGANI, 2005)

A forma mais simples de avaliar mudanças em imagens digitais se dá por meio de análise visual (CANTY, 2007). Este procedimento, ainda que válido, necessita de um grande esforço do analista, além do alto grau de subjetividade envolvido. Um grande conjunto de propostas metodológicas para detecção de mudanças tem sido investigado na literatura científica, entretanto os métodos baseados na chamada imagem de diferença são os mais amplamente utilizados (TENG et al., 2008; RADKE et al., 2005; BRUZZONE; PRIETO, 2000). Em tais abordagens, a imagem de diferença é gerada pela subtração, pixel a pixel, dos

contadores digitais das bandas espectrais de duas imagens da mesma área, coletadas em datas distintas. De acordo com Bruzzone e Prieto (2000), a escolha das bandas espectrais dependerá do tipo específico de alteração que se deseja detectar.

Existem fontes de variação indesejáveis que representam uma parcela do sinal registrado pelo sensor na geração das imagens. Estas fontes produzem ruídos que podem ser minimizados, mas não completamente eliminados. Tal constatação acrescenta à imagem da diferença um ruído amplificado (soma dos ruídos de ambas as imagens) que se mistura às verdadeiras alterações existentes na cena imageada. Isso significa que a imagem de diferença deverá conter, ao menos, duas populações de sinal: o ruído e as alterações na superfície. Theiler (2008) denomina essas duas populações de sutis e anômalas, sendo que esta última é associada às mudanças de interesse.

A separação dessas duas populações é frequentemente realizada por meio da definição de limiares, e a principal dificuldade consiste na determinação desses limites (ZANOTTA, 2010). Diferentes procedimentos envolvendo a separabilidade de classes são sugeridos na literatura; alguns dos principais serão discutidos no Capítulo 2.

1.1 TEMA E OBJETIVOS

A literatura científica que aborda o tema da detecção de mudanças na superfície terrestre por meio de imagens multiespectrais é extensa. No entanto, constata-se que há temas menos explorados, como a utilização de imagens de fração produzidas pelo Modelo Linear de Mistura Espectral (MLME) (SHIMABUKURO; SMITH, 1991). No MLME pressupõe-se que um espectro pode ser modelado pela combinação linear de espectros puros, conhecidos por *endmembers* (ROBERTS et al., 1998), de forma que, conhecendo-se as respostas espectrais dos componentes puros, as proporções destes podem ser estimadas, gerando as denominadas imagens de fração (SHIMABUKURO; SMITH, 1991; FERREIRA; FERREIRA; FERREIRA, 2008).

A proposição de utilizar imagens de fração para detecção de mudanças é motivada por quatro vantagens que elas apresentam em relação às imagens multiespectrais convencionais: 1) a correção radiométrica deixa de ser um problema crítico no espaço de frações, o que ocorre quando se trabalha diretamente com a resposta espectral; 2) a interpretação dos resultados é facilitada, visto que os componentes das imagens de fração têm um significado físico direto; 3) a dimensionalidade do problema é reduzida; e 4) existe a possibilidade da análise das alterações em um nível de subpixel. Esta última vantagem é bastante razoável em

imagens como a do sensor Landsat-TM, cuja resolução espacial corresponde a um pixel de 30×30m.

O **tema** desta tese envolve o uso de imagens de fração para detecção de mudanças na superfície sob a **hipótese** de que as quatro vantagens supracitadas, associadas a um *background* estatístico, permitem a geração de mapas de mudanças acurados e de fácil interpretação. O **objetivo geral** do trabalho é propor três algoritmos para detecção automática de mudanças, comparando-os entre si. A primeira proposta – rígida – consiste de uma abordagem estatística multivariada sobre o espaço de diferenças de fração, na qual os pixels são rotulados às classes de mudança ou de não-mudança. A segunda proposição flexibiliza os resultados da classificação rígida utilizando a tradicional técnica da regressão logística. A terceira proposta explora o conceito de subpixel dentro de uma lógica *fuzzy*, de forma que os pixels não são rotulados, mas, sim, são produzidas estimativas dos graus de pertinência à classe de mudança.

Os **objetivos específicos** do trabalho são:

- avaliar qualitativa e quantitativamente os resultados produzidos pelos três algoritmos;
- avaliar o efeito da escolha do nível de confiança sobre os resultados;
- avaliar o efeito do razão sinal-ruído (SNR) sobre os resultados a partir de imagens sintéticas;
- inferir sobre os tipos de mudança ocorridos na superfície terrestre.

1.2 ESTRUTURA DA TESE

Os capítulos subsequentes estão assim organizados:

Capítulo 2 – **Revisão Bibliográfica** com textos científicos encontrados na literatura e vinculados ao tema de detecção de mudanças. Optou-se pela separação entre as técnicas clássicas de detecção de mudanças, de pré-processamento e de propostas recentes, como o uso de imagens de fração para este fim. Neste capítulo, procurou-se minimizar o uso de notação matemática, apresentando, sempre que possível, o estado-da-arte da detecção de mudanças na forma de texto.

Capítulo 3 – **Métodos**, no qual são apresentadas as três propostas para detecção de mudanças e os pressupostos teóricos que as norteiam. Neste capítulo, a parte matemática foi enfatizada. Há uma inevitável intersecção entre os capítulos 2 e 3, pois não houve como apresentar as propostas da tese sem retomar as referências bibliográficas. Além das propostas,

a notação matemática necessária, a formalização do MLME, uma diferenciação entre métodos de classificação rígida, suave e *fuzzy* e uma breve descrição dos recursos computacionais são apresentadas.

Capítulo 4 – descreve os **Experimentos** realizados sobre pares de imagens sintéticas e reais, explorando os resultados. As imagens sintéticas são aquelas nas quais o pesquisador introduz propositalmente regiões de alteração sobre a imagem, tendo maior controle do experimento quando comparado aos que utilizam imagens reais. Este capítulo apresenta um vasto conjunto de resultados, os quais incluem mapas de mudança, avaliação quantitativa e análises comparativas.

Capítulo 5 – apresenta a **Conclusão** do estudo de acordo com os objetivos listados na seção 1.1, enfatiza as contribuições científicas da tese e traz recomendações para trabalhos futuros.

2. REVISÃO BIBLIOGRÁFICA

As primeiras publicações relacionadas ao tema de detecção de mudanças ocorreram na década de 60. Rosenfeld (1961) apresentou uma discussão de aplicações da detecção automática de mudanças na área de reconhecimento militar. Shepard (1964) destacou aspectos conceituais da detecção de mudanças, e Lillestrand (1972) enfatizou a economia computacional ao se representar apenas mudanças decorridas entre duas imagens tomadas em diferentes datas. No final da década de 80, Singh (1989) apresentou uma importante revisão sobre o tema, na qual classificou as técnicas de detecção de mudanças após um extenso levantamento bibliográfico. Bruzzone e Serpico (1997) também referenciam esta classificação.

Embora o trabalho de Singh (1989) continue sendo uma importante referência relacionada à detecção de mudanças, muitas técnicas foram propostas nos últimos anos. Lu et al. (2003) e Coppin et al. (2004) apresentam revisões mais recentes que incorporam novas proposições. Enquanto Singh (1989) lista dez diferentes técnicas para detecção de mudanças, Lu et al. (2003) apresentam 31 técnicas, sugerindo, inclusive, que as mesmas sejam agrupadas em sete diferentes categorias:

1. Álgebra
2. Transformações
3. Classificação
4. Modelos avançados
5. Abordagens de Sistemas de Informação Geográfica (SIG)
6. Análise Visual de Imagens
7. Outras abordagens.

A categoria *Álgebra* inclui técnicas que realizam operações matemáticas básicas entre bandas espectrais de imagens coletadas em datas distintas. Tais operações geram novas imagens sobre as quais um limiar para separação das classes ω_c e ω_{nc} é definido. A categoria *Transformações* inclui a conhecida técnica de análise multivariada, denominada Análise de Componentes Principais (ACP), a transformação Qui-quadrado ou distância de Mahalanobis e outras transformações comumente utilizadas no processamento de imagens digitais (e.g. *Tasseled Cap transformation*). A categoria *Classificação* engloba técnicas de detecção de

mudanças realizadas sobre imagens classificadas (métodos pós-classificação), bem como técnicas de classificação direta realizadas sobre a imagem de diferenças. A categoria *Modelos Avançados* inclui a utilização do MLME, modelos de reflectância e modelos de estimação de parâmetros biofísicos, dentre os quais o MLME é o mais frequentemente utilizado. As *Abordagens de SIG* consistem da habilidade de incorporar diferentes fontes de informação em estudos de detecção de mudanças. A *Análise Visual de Imagens*, como sugere o próprio nome, é uma categoria na qual a detecção de mudanças se baseia na interpretação visual de imagens multitemporais. Nesta categoria, a experiência e o conhecimento do analista podem ser totalmente explorados. O último grupo listado por Lu et al. (2003) – *Outras Abordagens* – é formado por técnicas que não se enquadram em um dos seis tipos anteriores ou por aquelas que foram pouco exploradas na literatura especializada.

Dentre todas as técnicas conhecidas, as mais utilizadas enquadram-se nos três primeiros grupos: *Álgebra*, *Transformações* e *Classificação*. Não há consenso sobre quais são as principais técnicas de detecção de mudanças, contudo, analisando autores como Almutairi e Warner (2010), Coppin et al. (2004) e Singh (1989), foi possível formar um conjunto das oito principais técnicas de detecção de mudanças:

1. Imagem de diferença univariada
2. Razão entre duas imagens
3. Análise do Vetor de Mudanças
4. Análise de Regressão
5. Análise de Componentes Principais
6. Índices de Vegetação
7. Classificação direta multidata
8. Detecção pós-classificação.

Na próxima seção, as técnicas listadas serão brevemente apresentadas.

2.1 PRINCIPAIS TÉCNICAS PARA DETECÇÃO DE MUDANÇAS

A técnica mais simples para detecção de mudanças é a *imagem da diferença univariada* baseada na operação de subtração entre os contadores digitais de um par de imagens registradas. Geralmente esta técnica é realizada separadamente para cada banda espectral e, sob a hipótese de haver poucas mudanças entre as imagens, o comportamento probabilístico dos contadores digitais dos pixels da imagem de diferença deverá revelar pixels de mudança nas caudas da distribuição (Figura 1).

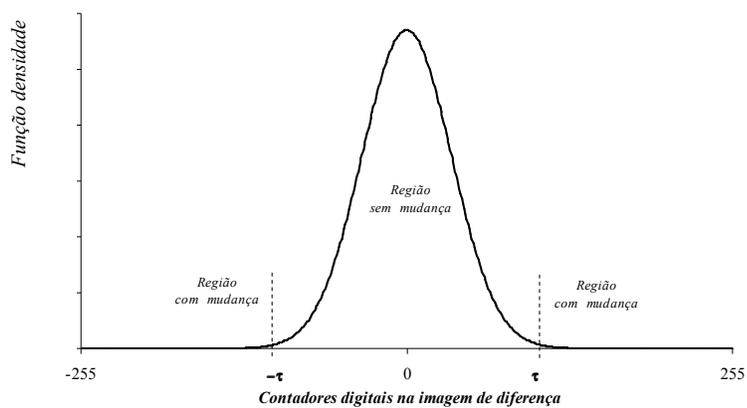


Figura 1 – Representação da função densidade dos contadores digitais dos pixels da imagem de diferença com a definição de um limiar (τ) entre as classes mudança e não-mudança

Outra técnica similar à diferença é a *razão entre duas imagens*. A razão entre os contadores digitais de imagens devidamente registradas e corrigidas radiometricamente deverá ser unitária nas regiões de não-mudança. De acordo com Singh (1989), os limiares entre as classes de mudança e não-mudança são geralmente definidos empiricamente.

Outra técnica similar às duas anteriores e amplamente utilizada é a *análise do vetor de mudanças* (MALILA, 1980; MICHALEK; LUCZKOVICH, 1993), mais conhecida pela sigla CVA, em referência ao termo em inglês *Change Vector Analysis*. Nesta abordagem, os pixels são tratados como vetores no espaço de feições, e as diferenças entre os vetores são computadas. A análise estatística da magnitude dos vetores permite detectar a presença de mudanças, enquanto as orientações indicam o tipo de alteração (BRUZZONE; SERPICO, 1997; COPPIN et al., 2004).

Um problema recorrente na detecção de mudanças e comum às três abordagens supracitadas é a definição do limiar de separação entre as classes mudança (ω_c) e não-

mudança (ω_{nc}). Bruzzone e Prieto (2000) apresentam uma abordagem não-supervisionada e paramétrica para definição automática do limiar de mudança.

A técnica de *detecção de mudanças por regressão* é um método onde os pixels da imagem coletada no tempo t_1 são assumidos como função linear dos pixels no tempo t_2 . A imagem em t_1 observada é comparada com aquela estimada por regressão, e a diferença entre elas é considerada um indicador de mudança. Assim como as técnicas anteriores, há necessidade da definição de um limiar para distinguir as classes ω_c e ω_{nc} .

A *análise de componentes principais* (ACP) é uma técnica estatística multivariada que permite redução de dimensionalidade, mantendo grande parte da informação contida na imagem original. As componentes extraídas do espaço de feições original são frequentemente comparadas por meio da subtração ou razão entre as componentes nas diferentes datas. Algumas componentes deverão ser eficazes na separabilidade entre ω_c e ω_{nc} .

Técnicas baseadas em *índices de vegetação* também são encontradas na literatura. Geralmente os índices de vegetação (e.g. NDVI) computados em diferentes datas são comparados por meio da operação de diferença ou razão (NELSON, 1983). O cálculo dos índices, realizado separadamente, em cada data, para posterior comparação, minimiza problemas radiométricos.

A *classificação direta multidata* é um método baseado na análise de uma medida que combine duas imagens, como a diferença, por exemplo. Se métodos supervisionados forem utilizados para classificação, são necessárias amostras de treinamento para todas as classes de transição consideradas, o que pode ser bastante difícil (Bruzzone e Serpico, 1997).

A *detecção de mudanças pós-classificação* é, segundo Singh (1989), o mais óbvio procedimento para detecção de mudanças. Nele as duas imagens são classificadas separadamente, considerando-se um conjunto de classes comum. A comparação é realizada por meio de tabulação cruzada, gerando a matriz de transição de classes, também conhecida como matriz de confusão. As técnicas de detecção de mudanças pós-classificação minimizam problemas de ordem radiométrica e são de fácil interpretação. Há, contudo, uma desconfiança quanto à acurácia da técnica pois, se tivermos, por exemplo, duas imagens classificadas com acurácia de 70%, espera-se que, na detecção de mudanças, a mesma caia para 49% ($0,70 \times 0,70$). Mas (1999), contrariando esta suspeita, obteve os melhores resultados entre seis métodos de detecção de mudanças com o procedimento pós-classificação.

As técnicas de detecção de mudanças podem ser classificadas em supervisionadas ou não-supervisionadas. Dentre as oito citadas, apenas as duas últimas são consideradas

supervisionadas. A necessidade de amostras de treinamento e, conseqüentemente, o conhecimento da verdade terrestre é o que caracteriza os procedimentos supervisionados (CELIK, 2009a).

Bruzzone e Serpico (1997) salientam que, em situações reais, é muito difícil contar com amostras de treinamento para todas as classes consideradas. Esse é o principal motivo pelo qual abordagens não-supervisionadas são mais abundantes na literatura recente. Para Bovolo e Bruzzone (2007), abordagens não-supervisionadas para detecção de mudanças desempenham um importante papel na análise de imagens multitemporais e, dentre elas, a mais amplamente utilizada é a CVA (DALLA MURA et al., 2008; BOVOLO; BRUZZONE, 2007).

Para Lu et al. (2003), as técnicas de detecção de mudanças podem, ainda, ser agrupadas em dois tipos de acordo com a informação presente no produto final típico derivado da técnica. O primeiro se preocupa em identificar se houve ou não alterações nas imagens de t_1 para t_2 , possibilitando a construção de mapas de detecção binários. O segundo grupo inclui aqueles métodos que procuram identificar a natureza das alterações, gerando mapas temáticos com diferentes classes.

Quadro 1 – Resumo das principais técnicas de detecção de mudanças e seus tipos

<i>Grupo</i>	<i>Natureza</i>	<i>Técnica</i>	<i>Produto final típico</i>
Álgebra	Não-supervisionada	Imagem de diferença	Mapa binário
		Razão entre duas imagens	Mapa binário
		Análise do Vetor de Mudanças	Mapa temático
		Análise de Regressão	Mapa binário
		Índices de vegetação	Mapa binário
Transformações	Não-supervisionada	Análise de Componentes Principais	Mapa binário
Classificação	Supervisionada	Direta Multidata	Mapa temático
		Pós-classificação	Mapa temático

Fonte: Construído pelo autor com base em Lu et al. (2003).

2.2 TÉCNICAS DE DETECÇÃO DE MUDANÇAS RECENTES

De um modo geral, todas as técnicas propostas na literatura têm por objetivo detectar reais alterações na superfície terrestre, reduzindo os esforços necessários na análise visual de imagens. No intuito de propor técnicas alternativas às usuais (seção 2.1), ou de formalizar técnicas consagradas, estudos têm sido reportados na literatura especializada.

Bruzzone e Serpico (1997) propõem um método de classificação supervisionado e não-paramétrico para detectar transições de classes entre duas imagens a partir de uma matriz cujas probabilidades são estimadas de maneira iterativa a partir de amostras de treinamento. Os resultados da técnica proposta pelos autores foram comparados com o tradicional método pós-classificação, mostrando-se superiores. Castellana, D’Addabbo e Pasquariello (2007) apresentam uma proposta semelhante, porém utilizando uma abordagem parcialmente supervisionada.

Bruzzone e Prieto (2000) propõem duas técnicas não-supervisionadas cuja estimação do limiar de mudanças entre as classes mudança e não-mudança se dá de forma automática, utilizando o algoritmo *Expectation Maximization* (EM). A primeira baseia-se na regra de Bayes para minimizar erros de classificação e supõe que os pixels são independentes; a segunda considera o contexto espacial baseado em Campos Aleatórios de Markov (MRF).

Bovolo, Bruzzone e Marconcini (2008) propõem um procedimento semi-supervisionado baseado em *Support Vector Machine* (SVM) e medidas de similaridade, o qual apresentou resultados superiores aos obtidos quando a proposta de Bruzzone e Prieto (2000) é utilizada.

Dentre os trabalhos mais recentes, destaca-se o de Bovolo e Bruzzone (2007), no qual os autores apresentam uma estrutura e um sólido *background* para a análise do vetor de mudanças no domínio polar, formalizando a tradicional técnica de *Análise do Vetor de Mudanças* (CVA). A magnitude do vetor indica a “força” da mudança, enquanto a orientação traz informações sobre a sua natureza. No espaço polar, os pixels de mudança tendem a se agrupar fora do círculo de raio T , que caracteriza a região de não-mudança (Figura 2). Neste mesmo trabalho, modelos probabilísticos que descrevem a magnitude (ρ) e a direção (ϑ) dos vetores para as classes mudança (ω_t) e não-mudança (ω_{nc}) são apresentados.

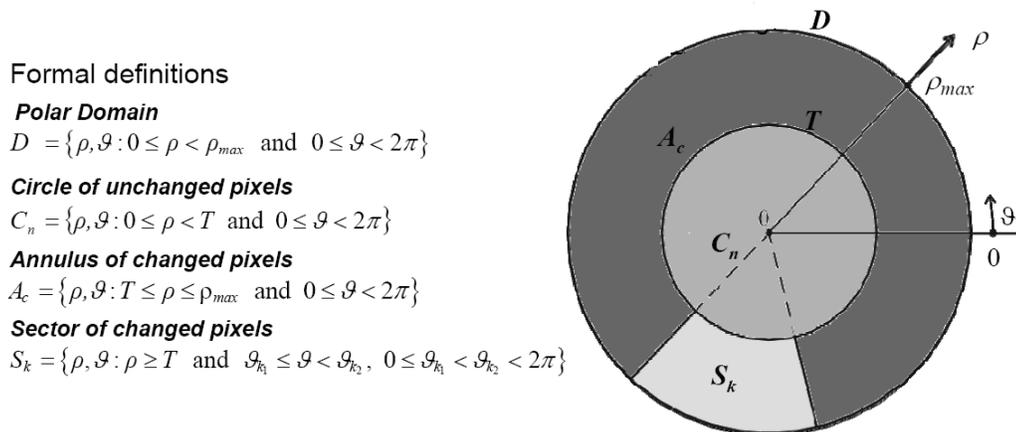


Figura 2 – Definições formais e localização das regiões de mudanças e não-mudança.

Fonte: Bovolo e Bruzzone (2007)

A Figura 3 mostra uma situação real em que os pixels correspondentes à classe de mudança (ω_c) se concentram numa região específica no espaço de coordenadas polares, fora do círculo que caracteriza a classe sem mudanças (ω_{nc}).

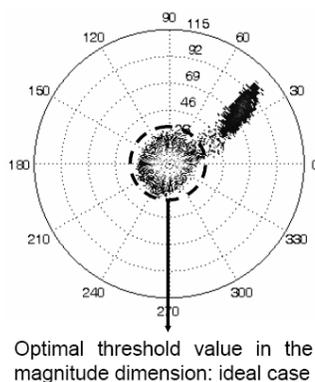


Figura 3 – Representação dos pixels no espaço de coordenadas polares usando a técnica de Análise do vetor de mudanças.

Fonte: Bovolo e Bruzzone (2007)

Celik (2009a) propõe um algoritmo computacionalmente simples e eficaz que divide a imagem em janelas de dimensão $h \times h$ sobre as quais o procedimento de ACP é aplicado e os autovalores são computados. O autor, utilizando a técnica de *cluster k*-médias, conseguiu êxito na separação entre as classes ω_c e ω_{nc} no espaço dos autovalores. Os resultados foram comparados aos obtidos por meio do uso das duas técnicas propostas por Bruzzone e Prieto (2000), mostrando-se superiores nas duas imagens consideradas. Celik (2009b) também

apresenta uma proposta baseada em ondaletas e outra baseada em algoritmos genéticos (CELIK, 2010). Em ambos os casos, os resultados foram comparados com as propostas de Bruzzone e Prieto (2000), sendo os resultados obtidos sempre mais acurados.

Apesar de as técnicas não-supervisionadas serem mais abundantes na literatura, Fraser, Fernandes e Latifovic (2002) utilizaram um procedimento supervisionado baseado em regressão logística para o mapeamento de áreas queimadas, de forma que foram necessárias amostras de treinamento para estimação dos parâmetros do modelo logístico. O algoritmo proposto, se utilizado diretamente, gera muitos erros de classificação, os quais foram minimizados com a aplicação de filtros que introduzem informação de contexto.

A maior parte das técnicas citadas nesta seção faz uso de informações de contexto (e.g. MRF), de forma que os pixels da imagem não são tratados de forma independente. A inclusão de informação de contexto espacial é discutida na próxima seção.

2.3 O CONTEXTO ESPACIAL NA DETECÇÃO DE MUDANÇAS

A inclusão do contexto espacial na classificação de imagens multiespectrais iniciou na década de 70, com as primeiras publicações ocorrendo na década de 80 (TILTON; VARDEMAN; SWAIN, 1982; SWAIN; VARDEMAN; TILTON, 1981; LANDGREBE, 1980; DI ZENZO et al., 1987). Como os relacionamentos de vizinhança são uma fonte de informação que não deve ser desprezada, abordagens que consideram o contexto espacial são abundantes na literatura de Reconhecimento de Padrões.

De acordo com Richards (1993), o contexto desempenha um importante papel no processamento de imagens digitais por dois motivos:

- a) os contadores digitais registrados por sistemas sensores referentes a um pixel coletam porções de energia de pixels vizinhos;
- b) o tipo de cobertura do solo correspondente a uma classe é, geralmente, muito maior do que o tamanho de um pixel (esta consideração não é válida para imagens de resolução muito alta).

Algoritmos de detecção de mudanças que tratam os pixels de maneira independente tendem a gerar mapas de mudanças ruidosos (RADKE et al., 2005). A maneira mais simples de solucionar este problema consiste na realização de operações pós-processamento, como a aplicação de filtros baseados em janelas móveis (TSO; MATHER, 2009). Tais operações

(e.g. Moda ou Mediana) podem ser aplicadas sobre imagens temáticas, sejam elas binárias ou não, e, geralmente, são eficientes na remoção do ruído *salt-and-pepper*.

Filtros morfológicos também podem ser incluídos na classe de operações pós-processamento para inclusão de informações de contexto. Filtros baseados em operações morfológicas removem pixels ruidosos e, além disso, têm a habilidade de preservar estruturas de interesse e características geométricas, de acordo com o elemento estruturante adotado (DALLA MURA et al., 2008; GONZALEZ et al., 2004). Operações morfológicas têm sido usadas em aplicações de sensoriamento remoto com três propostas: filtragem, segmentação e quantificação (SOILLE; PESARESI, 2002).

Um dos clássicos procedimentos encontrados na literatura é o de relaxação probabilística (HARRIS, 1985). Nele, as probabilidades de um dado pixel pertencer a uma classe ω_i são estimadas a partir de um processo iterativo que utiliza funções de vizinhança. Essas funções levam em consideração probabilidades condicionadas aos resultados encontrados dentro de uma área de vizinhança pré-definida.

Apesar de serem populares e frequentemente eficientes, abordagens pós-classificação tendem a produzir resultados menos acurados do que aquelas que incluem informação de contexto durante o processo de construção do mapa de mudanças. Nesse caso, destaca-se o uso de Campos Aleatórios de Markov (MRF) (RADKE et al., 2005). Pode-se afirmar que MRF consistem de uma das abordagens mais encontradas na literatura, tanto para inclusão da informação espacial como temporal. Destacam-se os trabalhos de Kasetkasem e Varshney (2002), Melgani e Serpico (2003) e Bruzzone e Prieto, (2000). Neste último, os autores apresentam resultados obtidos sem e com a inclusão do contexto via MRF. Os resultados encontrados após a inclusão da informação espacial foram muito superiores e praticamente eliminaram o ruído que costuma estar presente em imagens temáticas.

MRF têm sido amplamente utilizados em vários campos do processamento de imagens, tais como restauração de imagens, análise de textura e segmentação (MELGANI; SERPICO, 2003) e não apenas na classificação de imagens digitais (SOLBERG; TAXT; JAIN, 1996). De acordo com Therrien (1989), MRF é uma extensão das cadeias de Markov (unidimensionais) para o plano, onde há uma dependência bidimensional. Recentemente, Jia e Richards (2008) apresentaram um método baseado em MRF onde a contribuição espectral e espacial são separadas e ponderadas por coeficientes que variam no intervalo (0,1). Desta forma, os autores puderam mensurar a importância das duas componentes (espectral e espacial) no processo de classificação.

Estatísticas espaciais, especialmente *kriging*, também têm sido utilizadas para incorporar autocorrelação espacial na estimação de parâmetros. Boucher, Seto e Journel (2006) apresentam um método para mapear mudanças na cobertura do solo, incorporando informação espacial e temporal, utilizando geoestatísticas. Os resultados encontrados pelos autores apontam para um aumento da acurácia quando tais informações são incorporadas.

Pode-se concluir, portanto, que a informação de contexto espacial é necessária em estudos de processamento de imagens e, em especial, na detecção de mudanças. Por esta razão, estudos nessa linha são abundantes. Por outro lado, trabalhos que agreguem informação de contexto ao uso de imagens de fração na detecção de mudanças são raros.

2.4. O MODELO LINEAR DE MISTURA ESPECTRAL E A GERAÇÃO DE IMAGENS DE FRAÇÃO

Imagens de fração é o nome dado ao conjunto de imagens produzido pelo Modelo Linear de Mistura Espectral (MLME) para um dado conjunto de *endmembers* selecionados pelo pesquisador. A teoria que sustenta a geração dessas imagens baseia-se no conceito do pixel mistura, o qual considera que os sinais elétricos captados por um sensor remoto passivo são resultantes da interação entre a radiação solar e todos os alvos presentes na área referente a um pixel. Para Roberts et al. (1998), o espectro misturado pode ser modelado pela combinação linear de espectros puros (*endmembers*). Assim sendo, além da contribuição da atmosfera, a radiação registrada na forma de contadores digitais contempla diferentes materiais dentro do campo instantâneo de visão (IFOV) do sensor (SHIMABUKURO; SMITH, 1991).

A geração das imagens de fração inicia com a seleção de um conjunto de *endmembers* (ou componentes) representativos da cena em questão. Depois da seleção dos *endmembers*, as proporções desses componentes em cada pixel da imagem são estimadas através do método dos mínimos quadrados, adicionando a restrição de que a soma das frações seja unitária (SHIMABUKURO; SMITH, 1991; HAERTEL; SHIMABUKURO, 2005). Embora a geração de imagens de fração seja mais comum para imagens de média ou alta resolução espacial, Ferreira, Ferreira e Ferreira (2008) afirmam que, independentemente das resoluções espaciais dos sensores remotos, sejam estas de 60 cm, 30m ou 250m, os pixels de uma imagem de satélite tendem a apresentar uma mistura espectral. Os mesmos autores referem que,

normalmente, um pixel apresenta uma mistura, em menor ou maior proporção, de alvos contendo cobertura vegetal, solo e água (ou sombra).

A Figura 4 apresenta um exemplo de imagem Landsat-TM com seis bandas espectrais, cujas frações foram geradas considerando os *endmembers* vegetação, solo exposto e água. A definição formal do MLME será apresentada na seção 3.1 do próximo capítulo.

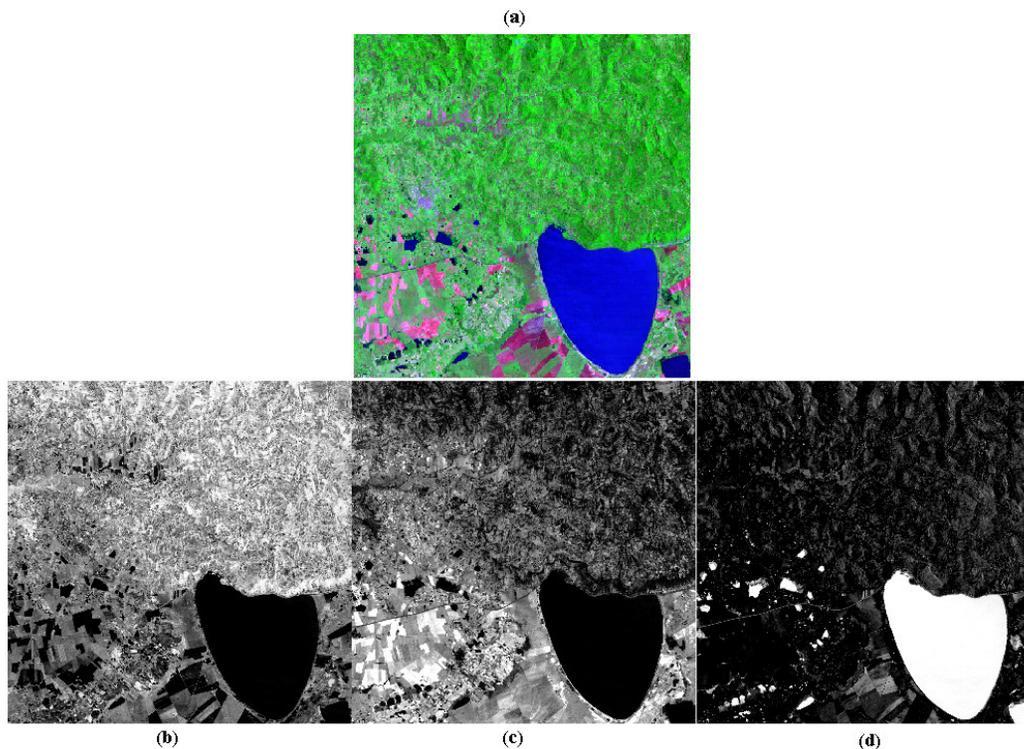


Figura 4 – Exemplo de segmento de imagem Landsat-TM, (a) composição colorida 7-4-1 (RGB). Conjunto de imagens de fração referentes à (b) vegetação, (c) solo exposto e (d) água.

2.5. O MODELO LINEAR DE MISTURA ESPECTRAL (MLME) EM ESTUDOS DE DETECÇÃO DE MUDANÇAS

Rogan, Franklin e Roberts (2002) constataam que o uso do MLME é um conceito relativamente novo em estudos de detecção de mudanças. Lu et al. (2003) reiteram essa afirmação, classificando as técnicas de detecção de mudanças baseadas em imagens de fração como avançadas.

Lu, Batistella e Moran (2004) afirmam que estudos de detecção de mudanças que utilizam imagens de fração construídas a partir do MLME têm se mostrado eficientes. Esta afirmação não se baseia apenas nos achados dos próprios autores, mas também em outros estudos publicados entre os anos de 1995 a 2005.

Adams et al. (1995) analisaram quatro imagens Landsat-TM de uma área situada na Amazônia brasileira a partir de imagens de fração, considerando os seguintes *endmembers*: vegetação fotossintética, vegetação não-fotossintética, solo e sombra. As imagens de fração foram usadas para definição de sete categorias, as quais poderiam ser compostas por mais de uma classe. A variação dessas classes no tempo foi utilizada para determinação de “superclasses” que agruparam pixels com históricos comuns. Esse estudo produziu resultados muito interessantes, mesmo não adotando técnicas estatísticas convencionais de classificação.

Shimabukuro et al. (1998) utilizaram a fração sombra para mapear e estimar áreas de desmatamento na floresta Amazônica. O mesmo procedimento foi utilizado por Verona, Shimabukuro e Santos (2001) para análise de mudanças ocorridas entre 1986 e 1999 na região de abrangência da Floresta Nacional do Tapajós em Santarém, PA. Os autores utilizaram composições coloridas com as frações de sombra nas duas datas e a diferença de frações. Todt (2007) propõe uma abordagem que integra dados multitemporais extraídos de imagens de fração com uma rede neural artificial para detecção de novos desflorestamentos em tempo real. Arai et al. (2011) também propõem uma nova técnica para o monitoramento do desflorestamento na Amazônia brasileira. Nesse estudo os autores propõem uma integração entre imagens MODIS e Landsat 7, sensor ETM+, de modo a aumentar a resolução espacial das imagens MODIS por meio de simulação e, assim, obter melhores estimativas da área desflorestada.

Além das aplicações para detecção de áreas de desmatamento, desflorestamento e reflorestamento, o MLME também tem sido utilizado com sucesso no monitoramento de queimadas (COCHRANE; SOUZA, 1998; SOUZA et al., 2003; SHIMABUKURO et al., 2009) e no estudo da relação entre clima e fenômenos biológicos periódicos (fenologia) na vegetação da Amazônia (ANDERSON et al., 2011).

Rogan, Franklin e Roberts (2002) realizaram um estudo de detecção de mudanças no uso e cobertura da terra no sul da Califórnia, EUA, no qual são feitas comparações entre a transformada de *Kauth-Thomas* e o MLME combinados com os classificadores de máxima verossimilhança gaussiana e árvores de decisão. Os resultados mostram que ambos os classificadores produzem melhores resultados quando realizados sobre imagens de fração derivadas do MLME.

Haertel, Shimabukuro e Almeida-Filho (2004) apresentaram uma abordagem não-supervisionada baseada em algoritmos de *clustering* para determinação de classes de mudança a partir de imagens de fração. O procedimento é matematicamente simples, porém requer um alto esforço do analista na interpretação dos resultados. Bittencourt e Haertel (2008)

propuseram uma abordagem supervisionada sobre a mesma área de estudo e encontraram resultados semelhantes.

Bittencourt e Haertel (2009), e, posteriormente Zanotta (2010), utilizaram o algoritmo *Expectation Maximization* (EM) para encontrar os parâmetros de duas distribuições normais multivariadas que deverão descrever as classes ω_c e ω_{nc} no espaço de diferenças de fração. Tais funções densidade possibilitaram a estimação de graus de pertinência à classe ω_c dentro de uma lógica *fuzzy*. A imagem resultante foi, então, submetida a um procedimento iterativo de relaxação probabilística que convergiu para uma imagem final mais acurada. Este procedimento será novamente discutido na seção 3.5, visto que ele suscitou a proposta *fuzzy* apresentada nesta tese.

Outros textos científicos sobre mudanças no uso e cobertura da superfície terrestre podem ser encontrados. No entanto, as obras citadas foram escolhidas de maneira a representar aquelas mais relacionadas ao tema de detecção de mudanças.

Mesmo que o uso de imagens de fração na detecção de mudanças apresente a vantagem de minimizar problemas radiométricos, independentemente do tipo de abordagem escolhida, a necessidade de pré-processamento é condição necessária em estudos deste tipo, seja por motivos radiométricos ou de registro.

2.6 PRÉ-PROCESSAMENTO

A premissa defendida por Singh (1989) de que as diferenças na cobertura da terra deverão ser captadas e registradas pelos sistemas sensores requer que tais mudanças sejam predominantemente reflexo de alterações de radiância e não causadas por outros fatores, tais como:

- diferentes condições atmosféricas;
- diferente ângulo de incidência do sol;
- diferenças na calibração do sistema sensor;
- problemas de registro.

Na mesma linha, Radke et al. (2005) afirmam que, dado que o objetivo da detecção de mudanças é separar diferenças importantes das não importantes (ruído), é necessário um pré-processamento que minimize os efeitos de causas de variação indesejáveis e que não caracterizam alterações de interesse. Coppin et al. (2004) consideram a maximização da razão

entre sinal e ruído (SNR) como um problema comum em aplicações envolvendo sensores remotos.

De fato, correções radiométricas e geométricas são um problema crítico na detecção de mudanças, tendo motivado um grande número de estudos. Dai e Khorram (1998) estudaram o efeito do problema de registro sobre a acurácia de vários algoritmos para detecção de mudanças, sugerindo que o erro de registro seja de, no máximo, 0,2 pixels. Coulter e Stow (2008), no entanto, relatam que produtos derivados de estudos de detecção de mudanças com imagens Landsat são frequentemente produzidos a partir de pares de imagens com erros de registro entre 0,5 e 1,0 pixel. A Figura 5 apresenta uma ilustração do que significa o erro de registro.

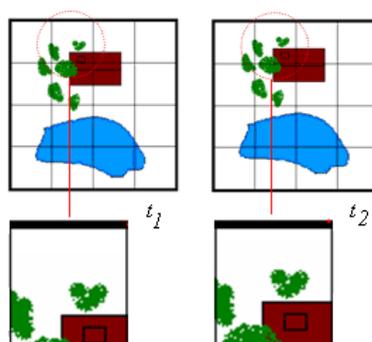


Figura 5 – O problema de registro entre duas imagens de uma mesma cena

Bruzzone e Cossu (2003) modelaram o ruído provocado pelo erro de registro sobre o espaço dos vetores de mudanças. Mais recentemente, Bovolo, Bruzzone e Marchesi (2007), em estudo semelhante, estudaram o efeito dos erros de registro na comparação de imagens de alta resolução espacial, conseguindo, com êxito, encontrar propriedade de estacionariedade nos vetores de mudança sobre o domínio polar. Para uma completa revisão sobre métodos para registro de imagens, recomenda-se Zitová e Flusser (2003).

Os problemas de registro podem ser minimizados criando-se uma nova imagem onde os contadores digitais da imagem original em t_2 são ponderados de acordo com os percentuais de sobreposição com os pixels vizinhos, conforme o *grid* da imagem de referência em t_1 .

Em relação às correções radiométricas, Mas (1999) sustenta que elas são necessárias, visto que não é possível coletar duas imagens sob as mesmas condições. A performance radiométrica varia devido às condições de iluminação solar, espalhamento e absorção atmosférica, presença de nuvens, entre outras. Há duas maneiras usuais de realizar correções atmosféricas com o objetivo de tornar as imagens coletadas em t_1 e t_2 comparáveis. A primeira

é realizar uma calibração radiométrica, convertendo os contadores digitais em valores de reflectância. A segunda é realizar uma normalização radiométrica relativa entre as duas imagens. De acordo com Mas (1999), o primeiro procedimento é mais complexo, o que torna o segundo procedimento mais prático e usual.

2.7 ESTUDOS COMPARATIVOS

Estudos de detecção de mudanças comumente empregam várias técnicas, dentre as quais o pesquisador seleciona aquela que apresenta melhor desempenho (Lu et al., 2003). A literatura revela que, mesmo quando o maior interesse do pesquisador não é a comparação entre métodos, frequentemente algum tipo de comparação é adotada, a fim de possibilitar que os resultados sejam relativizados. Este procedimento é indispensável quando o pesquisador não dispõe de verdade terrestre ou de imagem de referência. Embora um grande número de estudos apresente algum tipo de comparação entre técnicas, apenas aqueles cuja principal motivação foi a de comparação são apresentados nesta seção.

Mas (1999) comparou seis procedimentos de detecção de mudanças sobre imagens Landsat-MSS coletadas nos anos de 1974 e 1992. Dentre as seis técnicas utilizadas, o autor obteve os melhores resultados com a *Detecção pós-classificação*. Já Muchoney e Haack (1994), comparando praticamente os mesmos procedimentos em um estudo de desfolhamento, encontraram resultados produzidos pela ACP e *Imagem de Diferença* superiores aos obtidos com o uso da *Detecção pós-classificação*. Macleod e Congalton (1998), em um estudo de monitoramento de algas, utilizando imagens Landsat-TM de 1990 e 1992, também compararam estes procedimentos contra uma imagem de referência. Eles encontraram os melhores resultados com a técnica da *Imagem de diferença*.

Yuan e Elvidge (1998) testaram e avaliaram 75 técnicas e variações para detecção de mudanças, utilizando análise estatística e visual de imagens. Os experimentos foram realizados sobre imagens Landsat-MSS de Washington D.C., Estados Unidos. Os pesquisadores utilizaram imagens de diferença e de razão, sendo que as imagens de diferença apresentaram, de uma forma geral, resultados superiores.

Ridd e Liu (1998) compararam quatro algoritmos para detecção de mudanças sobre um par de imagens Landsat-TM da área metropolitana de Salt Lake City (EUA). Eles utilizaram as técnicas da *Imagem de Diferença Univariada*, *Análise de Regressão*, a

transformada *Kauth-Thomas* e a transformação Qui-quadrado. Os resultados mostraram que a acurácia dos métodos depende fortemente das classes e das bandas espectrais consideradas.

O estudo de Rogan, Franklin e Roberts (2002) é um dos únicos que apresenta um comparativo entre resultados de detecção de mudanças produzidos com o uso de imagens de fração e outra técnica. Os autores concluem que o uso do MLME na detecção de mudanças produz melhores resultados do que a transformada de Kauth-Thomas.

Mais recentemente, Almutairi e Warner (2010) compararam os procedimentos de *Imagem de diferença*, *Análise do Vetor de Mudanças*, *Análise de Componentes Principais (ACP)*, *Classificação Direta Multidata* e *Detecção pós-classificação* sobre um conjunto de imagens simuladas com diferentes níveis de ruído, de correlação entre as bandas e diferentes níveis de separabilidade entre as classes consideradas. O estudo mostrou que os resultados produzidos pelas diferentes técnicas variam muito. Entretanto, de uma forma geral, a *Classificação Direta Multidata* levou aos melhores resultados de acurácia, e a ACP produziu resultados com os menores índices de acurácia. Apesar dessa conclusão, os autores salientam que não existe um método de detecção de mudanças que produza os melhores resultados em todas as situações.

A inexistência de consenso sobre qual o melhor método de detecção de mudanças é perceptível nos estudos comparativos. Tal constatação reforça que não existe um único método que seja adequado para todos os casos (LU et al., 2003).

2.8 MEDIDAS DE AVALIAÇÃO DE DESEMPENHO

A produção de mapas binários ou temáticos que identificam classes de mudança na superfície terrestre é uma das aplicações mais comuns em estudos de detecção de mudanças na área de sensoriamento remoto (FOODY, 2002). Esses produtos estão sujeitos a erros, de forma que se faz necessário avaliar o desempenho dos algoritmos utilizados na geração desses mapas. Dois procedimentos têm sido reportados na literatura (RADKE et al., 2005):

- análise visual ou qualitativa;
- análise estatística ou quantitativa.

A avaliação qualitativa de um mapa de mudanças consiste da apresentação de um ou mais mapas sobre os quais o analista realiza uma inspeção visual e conclui a partir do seu

conhecimento sobre a área de estudo. Outro procedimento comum nesse tipo de abordagem é a apresentação sobreposta do mapa de mudança e imagens da área de estudo.

A avaliação quantitativa baseia-se em indicadores extraídos da matriz de confusão entre os resultados observados e a chamada “verdade terrestre”. Em se tratando de um algoritmo que gera mapas de mudança binários ($\omega_{nc}=0$ e $\omega_c=1$), a matriz de confusão assume a sua forma mais simples (dimensão 2×2 .), conforme ilustra a Tabela 1.

Tabela 1 – Matriz de confusão para avaliação de algoritmos de detecção de mudanças binários

<i>Classe predita</i>	<i>Verdade terrestre</i>	
	ω_c ou +	ω_{nc} ou –
ω_c ou +	<i>a</i>	<i>b</i>
ω_{nc} ou –	<i>c</i>	<i>d</i>

Assumindo que $N = a + b + c + d$, as medidas quantitativas frequentemente extraídas da matriz de confusão (FOODY, 2002; LU et al., 2003; RADKE et al., 2005; FAWCETT, 2006) podem ser assim obtidas:

a) Acurácia (τ) – definida como a proporção geral de pixels corretamente classificados, conforme a Equação (1):

$$\tau = \frac{a + d}{N}. \quad (1)$$

b) Coeficiente de concordância de *Kappa* (k) – medida do grau de concordância entre duas classificações proposta por Cohen (1960) e amplamente utilizada em aplicações de processamento de imagens (CONGALTON, 1991). O coeficiente k é uma espécie de acurácia que desconsidera a probabilidade de acerto casual, sendo calculado por (Equação 2):

$$k = \frac{p_e - p_o}{1 - p_o}, \text{ onde} \quad (2)$$

$$p_o = \frac{a + d}{N} \quad \text{e} \quad p_e = \frac{(a + c)(a + b) + (b + d)(c + d)}{N^2}.$$

c) Taxa de Falsos Alarmes (FA) – proporção de pixels que não sofreram mudanças dentre aqueles classificados como ω_c ou +. Também conhecida como Taxa de Falsos Positivos (FP), é calculada pela Equação 3.

$$FA = \frac{b}{a + b} \quad (3)$$

d) Taxa de detecção (DR) – proporção de pixels classificados como positivos dentre aqueles que são verdadeiramente positivos. Também conhecida como Acurácia do usuário, é obtida pela Equação 4.

$$DR = \frac{a}{a + c} \quad (4)$$

Outras medidas podem ser ainda derivadas de uma matriz de confusão 2×2 , como os coeficientes de Yule e Jaccard (ROSIN; IOANNIDIS, 2003) e o *F-score* (FAWCETT, 2006). Há de se ressaltar que, dependendo da área de conhecimento, os termos associados às medidas quantitativas podem variar. Na Epidemiologia, por exemplo, a taxa de detecção (DR) é conhecida como Sensibilidade ou *Recall*. Na área de Inferência Estatística, os falsos-alarmes são associados ao Erro tipo I (α). Há ainda a terminologia muito usada em Processamento de Imagens: Erros de Omissão e de Inclusão.

De acordo com Foody (2002), dentre todos os métodos de avaliação de desempenho de algoritmos de detecção de mudanças, a matriz de confusão é o mais utilizado. Outra ferramenta que pode ser empregada na avaliação de algoritmos é a curva ROC (*Receiver Operating Characteristics*), uma técnica para visualização, organização e seleção de classificadores de acordo com o desempenho (FAWCETT, 2006). Na área das ciências da saúde, as curvas ROC têm sido amplamente utilizadas para testes diagnósticos (ZWEIG; CAMPBELL, 1993) e, especialmente a partir do trabalho de Spackman (1989), têm figurado como uma importante ferramenta para comparação de algoritmos na área de *Machine Learning*. Por definição, uma curva ROC é um gráfico que permite a visualização no plano da taxa de detecção (DR) e da taxa de falsos alarmes (FA) a partir de resultados empíricos. Os pontos podem representar, por exemplo, o desempenho de diferentes classificadores, sendo que a coordenada (0,1) corresponde ao classificador ideal. A Figura 6, adaptada de Fawcett (2006), representa o desempenho de cinco classificadores, nomeados de A até E, dentre os quais o algoritmo D foi o melhor.

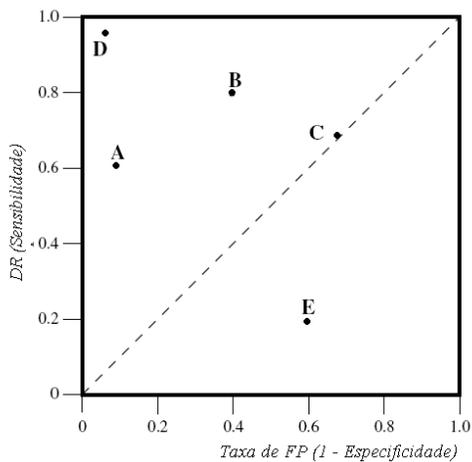


Figura 6 – Exemplo de curva ROC para avaliação de desempenho de cinco classificadores.

Fonte: Adaptado de Fawcett (2006, p. 862)

Apesar de serem conceitualmente simples, as curvas ROC têm sido objeto de estudo em diferentes áreas do conhecimento. Medidas derivadas dela permitem a aplicação de técnicas de inferência estatística, tais como intervalos de confiança e testes de hipóteses.

Uma característica comum às medidas apresentadas nesta seção é que todas elas pressupõem o conhecimento da verdade terrestre, ou seja, que haja disponibilidade de informação de campo em diferentes datas, coincidindo com a data de aquisição das imagens. Isso pode ser bastante difícil em aplicações reais (BRUZZONE; SERPICO, 1997), de forma que muitos estudos de detecção de mudanças têm sido conduzidos e avaliados a partir de conjuntos de imagens sintéticas (BRUZZONE; PRIETO, 2000; CELIK, 2009b).

Imagens sintéticas são produzidas a partir de uma imagem real. Uma cópia desta imagem é gerada e, sobre ela, são adicionadas regiões de mudanças que procuram simular reais alterações de superfície. Diferentes níveis de ruído podem ser adicionados à imagem, de forma a reproduzir uma situação real na qual a imagem em t_2 é composta de reais alterações de superfícies e ruído. O ruído pode ser aditivo ou multiplicativo (*speckle*), sendo este último presente em imagens de radar. Apesar de o ruído poder seguir qualquer modelo probabilístico, em imagens digitais geradas por sensores remotos passivos, o modelo gaussiano é comumente assumido. A Figura 7 mostra um exemplo de geração de imagem sintética.

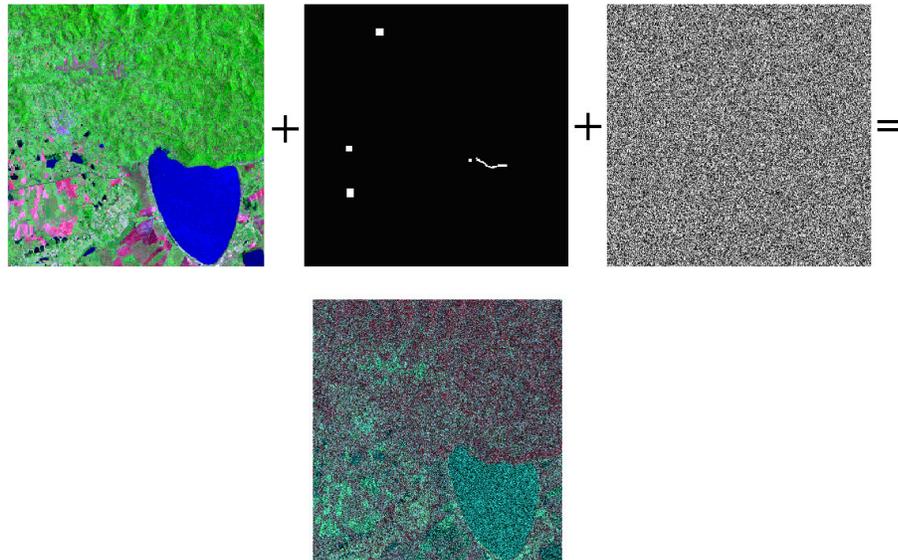


Figura 7 – Exemplo ilustrativo do processo de geração de imagens sintéticas

A intensidade de informação presente em um sinal é expressa por uma importante medida chamada de relação sinal-ruído (SNR). De uma forma geral, a SNR é expressa pela razão entre a variância do sinal (X) e variância do ruído (e), conforme a Equação 5 (GUSTAFSSON, 2000; CANTY, 2007):

$$SNR = \frac{Var(X)}{Var(e)} \quad (5)$$

Quanto maior o valor da SNR, menor é a intensidade do ruído presente no sinal. Na área de processamento de imagens, costuma-se expressar a SNR em decibéis (dB), seguindo uma transformação logarítmica, conforme mostra a Equação (6).

$$SNR = 10 \log_{10} \left(\frac{Var(X)}{Var(e)} \right) \quad (6)$$

Imagens com $SNR \leq 10$ dB são bastante ruidosas, enquanto imagens acima de 40dB apresentam grande nitidez. Celik (2009b) utilizou uma variação do SNR, denominada *peak signal-to-noise ratio* (PSNR), entre 20dB e 50dB, o que equivale a valores de SNR entre 10 e 40dB, faixa utilizada nesta tese.

3. MÉTODOS

As três propostas de algoritmos para detecção de mudanças que constam desta tese utilizam imagens de fração geradas pelo Modelo Linear de Mistura Espectral (MLME) (SHIMABUKURO e SMITH, 1991). As próximas seções detalham o MLME e as propostas. A notação matemática utilizada para identificação dos principais elementos é apresentada nas páginas iniciais da tese.

3.1 MODELO LINEAR DE MISTURA ESPECTRAL (MLME)

O MLME consiste em um sistema de equações lineares que relaciona a resposta espectral do pixel às respostas das classes consideradas como *endmembers*. Conforme Schowengerdt (2007), um *endmember* consiste de uma assinatura espectral pura idealizada para uma classe.

A Equação 7 apresenta a forma matricial do modelo que relaciona a resposta espectral de um dado pixel p -dimensional aos m *endmembers*. O sistema é acrescido do termo do erro (ϵ_i), visto tratar-se de um modelo de natureza estatística.

$$\mathbf{x}(i, j) = \mathbf{R} \times \mathbf{f}(i, j) + \boldsymbol{\epsilon} \quad \begin{array}{l} i = 1, 2, \dots, N \\ j = 1, 2, \dots, M \\ p > m \end{array} \quad (7)$$

$p \times 1$ $p \times m$ $m \times 1$ $p \times 1$

O mesmo sistema pode ser visto de maneira detalhada na Equação 8. Por questões de notação, o termo que refere a posição do pixel (i, j) foi omitido.

$$\begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_p \end{bmatrix} = \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1m} \\ r_{21} & r_{22} & \dots & r_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ r_{p1} & r_{p2} & \dots & r_{pm} \end{bmatrix} \times \begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_m \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_p \end{bmatrix} \quad (8)$$

A Equação 9 traz as duas restrições que são adicionadas, de forma que os componentes do vetor $\mathbf{f}(i, j)$, as estimativas $f_e(i, j)$ ($e=1, 2, \dots, m$), venham a representar as frações de cada *endmember* dentro de um pixel (SHIMABUKURO e SMITH, 1991).

$$f_e(i, j) \geq 0 \quad \text{e} \quad \sum_{e=1}^m f_e(i, j) = 1 \quad \begin{matrix} i = 1, 2, \dots, N \\ j = 1, 2, \dots, M \end{matrix} \quad (9)$$

Ao considerar um número de componentes (m) menor do que o número de bandas espectrais (p), o sistema pode ser solucionado por diferentes métodos. Neste trabalho optou-se pelo método dos mínimos quadrados com restrições, um dos procedimentos descritos em Shimabukuro e Smith (1991).

As respostas espectrais que formam o vetor \mathbf{x} e a matriz \mathbf{R} podem ser expressas em termos de reflectância espectral, radiância espectral ou número digital (HAERTEL; SHIMABUKURO, 2005).

Ao considerar a resposta espectral de um pixel como combinação linear dos *endmembers*, a seleção desses componentes puros torna-se uma etapa crítica do processo. De acordo com Schweik e Green (1999) e Ferreira (2003) há três formas para seleção de *endmembers*:

- a) bibliotecas espectrais construídas a partir de espectrorradiômetros de campo ou de laboratório;
- b) bibliotecas espectrais elaboradas a partir de estudos prévios usando MLME;
- c) seleção de pixels considerados “puros” na própria imagem.

Carvalho Jr. et al. (2003) fazem a distinção entre *endmembers* verdadeiros e da imagem. Para esses autores, a diferença conceitual é importante para compreender as limitações e ajustes necessários no processo de seleção dos mesmos. *Endmembers* verdadeiros só podem ser obtidos a partir da utilização de espectrorradiômetros (opções *a* e *b*). A opção *c* selecionará os pixels cujos espectros são os mais puros presentes na imagem. Esses pixels geralmente são obtidos utilizando-se geometria do tipo *simplex*. Para Ferreira (2003), a opção *c* é comumente empregada pela conveniência de não ser necessária a utilização de um espectrorradiômetro e, também, pela dificuldade de encontrar um espectro puro adequado ao objetivo da pesquisa.

O método *simplex*, ilustrado na Figura 8, seleciona candidatos a *endmembers* a partir de um diagrama de dispersão entre duas bandas espectrais úteis para discriminação entre os componentes puros. Os pixels alocados próximos aos vértices do triângulo hipotético são candidatos a *endmembers*.

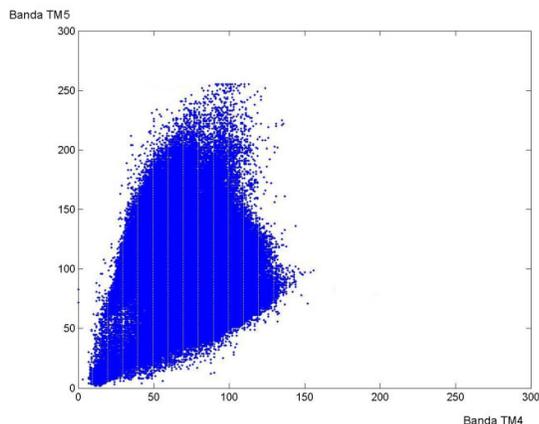


Figura 8 – Exemplo ilustrativo da utilização de diagrama de dispersão para seleção de pixels candidatos a *endmembers*

A Figura 9 sintetiza as etapas básicas para a geração das imagens de fração.

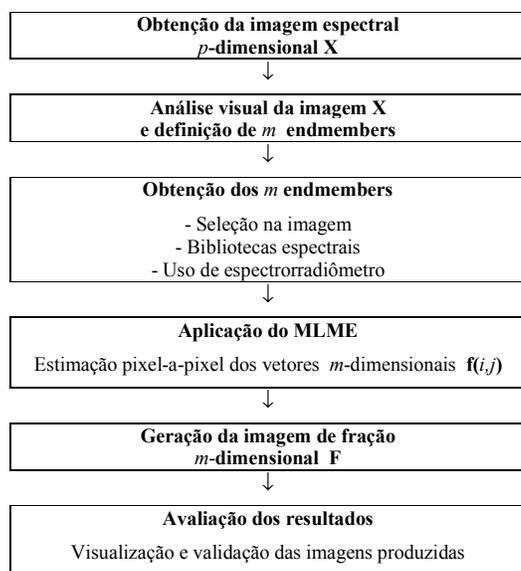


Figura 9 – Etapas básicas para a geração de uma imagem de fração a partir de uma imagem espectral

A Figura 10 apresenta um exemplo de utilização do MLME para geração de imagens de fração tridimensional a partir de seis bandas do satélite Landsat-TM.

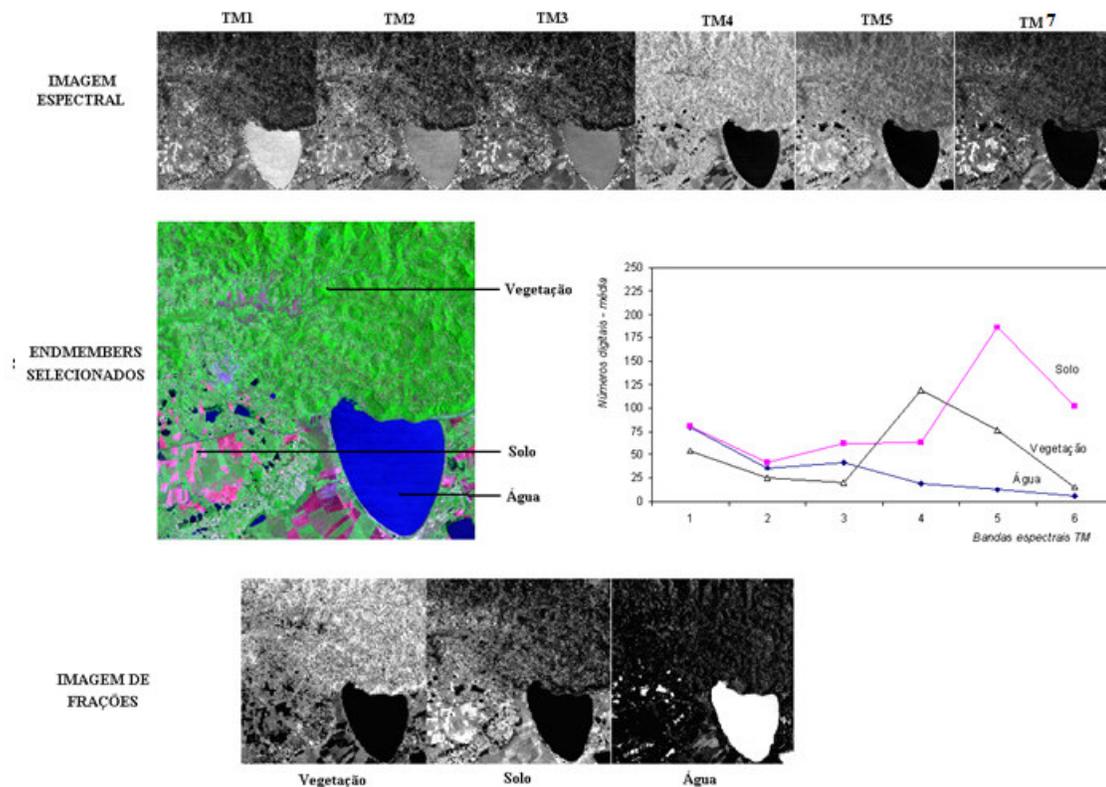


Figura 10 – Exemplo da geração de imagens de fração a partir de uma imagem Landsat-TM

3.2 MÉTODOS DE CLASSIFICAÇÃO RÍGIDA, SUAVE E FUZZY

A classificação pode ser definida como uma tarefa de processamento de informação na qual entidades são mapeadas em categorias gerais. No caso da classificação de imagens digitais, as entidades geralmente são pixels, e as informações provêm de um conjunto de p bandas espectrais originado em algum sistema sensor.

A forma mais comum de classificação é conhecida como *dura* ou *rígida*. Nesse tipo de classificação, os limites de decisão entre as classes são bem definidos, de forma que cada pixel é atribuído a uma única classe (FERREIRA, 2003). Assim, um pixel $\mathbf{x}(i,j)$, ao ser alocado à classe ω_i , exclui a possibilidade de ser alocado a qualquer outra classe ω_j ($i \neq j$).

Os métodos de classificação rígidos são divididos em dois tipos: os *supervisionados* e os *não-supervisionados*. Os métodos supervisionados requerem conhecimento prévio da área de estudo por parte do analista. Tal conhecimento permite a definição de um conjunto de classes $\Omega = \{\omega_1, \dots, \omega_k\}$ para as quais serão selecionadas amostras de treinamento utilizadas como dado de entrada em algoritmos de classificação. Os métodos não-supervisionados, por

sua vez, não requerem amostras de treinamento e tampouco definição prévia das classes que compõem a imagem. Os métodos não-supervisionados são quase um sinônimo para algoritmos de agrupamento ou *clustering*. Em geral, depois de escolhido o algoritmo, a única intervenção do analista dá-se na definição do número de grupos a ser criado.

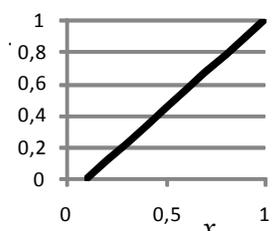
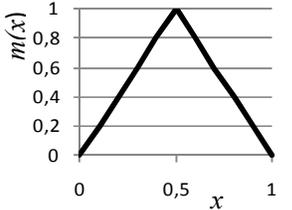
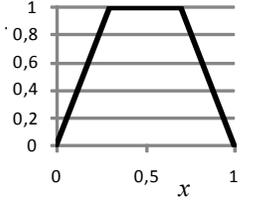
Os métodos de classificação rígida podem ser, ainda, subdivididos em *paramétricos* e *não-paramétricos*. Os métodos paramétricos requerem a suposição de modelos probabilísticos subjacentes nas classes consideradas, os quais são descritos por conjuntos de parâmetros a serem estimados. Os métodos não-paramétricos, ou de distribuição livre, não fazem suposição quanto à forma funcional dos dados de entrada, ou seja, não é necessária a especificação de um modelo que descreva o comportamento probabilístico dos padrões em cada classe.

A classificação *suave*, conforme Cheng, Varshney e Arora (2006), não designa um pixel a uma classe, mas, sim, atribui a ele uma probabilidade ou grau de pertinência a uma classe de Ω . Dentre as técnicas capazes de realizar classificação suave, pode-se destacar: regressão logística, redes neurais, algoritmo *c-means fuzzy* e regressão por árvores de decisão (CHENG; VARSHNEY; ARORA, 2006).

O termo *fuzzy* é associado à classificação suave, pois a teoria da lógica *fuzzy* provê conceitos e ferramentas capazes de lidar com informação imprecisa (WANG, 1990), o que necessariamente ocorre nesse tipo de classificação. A lógica *fuzzy*, ou lógica difusa, é uma extensão da lógica binária, admitindo infinitos valores intermediários entre o falso (0) e o verdadeiro (1). O termo lógica *fuzzy* emergiu a partir dos trabalhos de Zadeh (1965, 1968), entretanto Wilkinson (1963) já havia publicado uma obra com os mesmos conceitos, porém não havia utilizado este termo.

Segundo Tso e Mather (2009), a diferença entre conjuntos *fuzzy* e rígidos pode ser caracterizada por meio da função de pertinência $m(x)$. Enquanto em um conjunto rígido, $m(x)$ pode assumir apenas dois valores – 0 e 1 –, o conceito de conjuntos *fuzzy* suaviza essa restrição, permitindo graus de pertinência parciais para diferentes grupos ou classes. Assim, um mesmo elemento x pode ter graus de pertinência não-nulos para diferentes classes. O processo de associação de um grau de pertinência a um elemento x se chama *fuzzificação*. O Quadro 2 apresenta três funções que geralmente são empregadas nesta etapa.

Quadro 2 – Exemplo de funções de pertinência utilizadas no processo de *fuzzificação*.

Nome	Função	Representação gráfica
Monotônica linear	$\begin{cases} m(x) = 1 - \frac{a-x}{\lambda}, & 0 \leq a-x \leq \lambda \\ m(x) = 0 & , \text{ caso contrário} \end{cases}$	
Triangular	$\begin{cases} m(x) = 1 - \frac{ x-a }{\lambda}, & 0 \leq x-a \leq \lambda \\ m(x) = 0 & , \text{ caso contrário} \end{cases}$	
Trapezoidal	$\begin{cases} m(x) = \min\left\{2 - \frac{2 x-a }{\lambda}; 1\right\}, & a-\lambda \leq x \leq a+\lambda \\ m(x) = 0 & , \text{ caso contrário} \end{cases}$	

Fonte: Adaptado de Tso e Mather (2009)

No contexto de classificação de imagens, a lógica *fuzzy* é de fundamental importância em situações nas quais o conjunto de classes consideradas não é excludente. Na classificação de imagens digitais, o problema do pixel misto está em sintonia com as premissas da lógica *fuzzy*, uma vez que um pixel pode ser ocupado por mais de uma classe. Essa característica motivou Wang (1990) a apresentar uma proposta *fuzzy* para classificação de imagens digitais. Em sua proposta, Wang (1990) estima os graus de pertinência às classes ω_i sob a hipótese de que as mesmas sigam uma distribuição gaussiana, cujos parâmetros (vetor média *fuzzy* e matriz covariância *fuzzy*) são estimados de maneira iterativa.

Tso e Mather (2009) afirmam que a utilização de modelos de mistura espectral é uma importante área de pesquisa, na qual o conceito *fuzzy* se mostra adequado. Ferreira (2003), ao se referir ao MLME, vai além, sugerindo que as próprias imagens de fração podem ser vistas como uma espécie de classificação suave dos *endmembers* considerados.

A opção por um classificador rígido ou suave é escolha do pesquisador. Ao menos conceitualmente, a classificação suave parece estar mais próxima da realidade, ao permitir

que mais de uma classe seja associada a um mesmo pixel. No entanto, os classificadores rígidos continuam sendo populares.

3.2.1 Probabilidade versus Graus de Pertinência

Todo o procedimento de classificação *fuzzy* pode ser considerado suave, mas nem todo o procedimento suave é *fuzzy*. Essa afirmação decorre do fato de que a classificação suave pode ser realizada por meio da estimação de probabilidades ou de graus de pertinência, entretanto a classificação *fuzzy* pode apenas gerar graus de pertinência. Para melhor entendimento, há de se destacar as diferenças conceituais entre a Teoria das Probabilidades e a lógica *fuzzy*.

A Teoria das Probabilidades, alicerçada sobre os axiomas de Kolmogorov, não é capaz de lidar com a imprecisão no evento, pois, uma vez que se conhece o resultado de um experimento aleatório, não há mais dúvida sobre o seu resultado (RENTERIA, 2006). Isso quer dizer que a probabilidade é uma medida associada a eventos rígidos. Por exemplo, quando se define o espaço amostral como $\Omega = \{\omega_c, \omega_{nc}\}$, do ponto de vista da Teoria das Probabilidades, calcula-se a probabilidade de uma entidade por inteiro pertencer a uma das classes: ω_c ou ω_{nc} . Isso pode não ser verdade no caso de um pixel.

A lógica *fuzzy*, por sua vez, é capaz de lidar com a imprecisão no evento, permitindo que uma mesma entidade assuma graus de pertinência a diferentes classes. Kosko (1990) afirma que a lógica *fuzzy* considera a ambiguidade no evento, de forma que o grau com que um evento ocorre é medido e não a sua ocorrência. Portanto, o grau de pertinência a uma classe não deve ser confundido com uma probabilidade, mesmo que o fato de ambos variarem no intervalo $[0,1]$ possa sugerir uma falsa semelhança.

Nas próximas seções serão apresentados três classificadores – rígido, suave e *fuzzy* – a serem utilizados sobre imagens de diferença de fração.

3.3 PROPOSTA DE UM CLASSIFICADOR RÍGIDO PARA DETECÇÃO DE MUDANÇAS

Consideremos que F_1 e F_2 representem duas imagens de fração da mesma cena, devidamente registradas, mas coletadas em duas datas distintas (t_1 e t_2). A operação de

subtração entre essas duas imagens ($\mathbf{F}_2 - \mathbf{F}_1$) produz a imagem de diferença de frações, denotada por \mathbf{D} .

A restrição de que a soma das m frações que compõem um pixel seja unitária gera uma situação de redundância, na qual a m -ésima componente pode ser obtida por diferença em t_1 e t_2 , conforme mostra a Equação (10).

$$\mathbf{f}^1 = \begin{bmatrix} f_1^1 \\ f_2^1 \\ \vdots \\ f_m^1 \end{bmatrix} \quad \text{e} \quad \mathbf{f}^2 = \begin{bmatrix} f_1^2 \\ f_2^2 \\ \vdots \\ f_m^2 \end{bmatrix} \quad f_m^t = 1 - \sum_{e=1}^{m-1} f_e^t, \quad t=1 \text{ ou } 2 \quad (10)$$

Consequentemente, o vetor de diferenças de fração \mathbf{d} também tem uma m -ésima componente redundante, conforme mostram as Equações (11) e (12).

$$\mathbf{d} = \mathbf{f}^2 - \mathbf{f}^1 \quad \mathbf{d} = \begin{bmatrix} f_1^2 \\ f_2^2 \\ \vdots \\ f_m^2 \end{bmatrix} - \begin{bmatrix} f_1^1 \\ f_2^1 \\ \vdots \\ f_m^1 \end{bmatrix} = \begin{bmatrix} f_1^2 - f_1^1 \\ f_2^2 - f_2^1 \\ \vdots \\ f_m^2 - f_m^1 \end{bmatrix} \quad \text{onde} \quad f_m^t = 1 - \sum_{e=1}^{m-1} f_e^t \quad t=1 \text{ ou } 2. \quad (11)$$

Logo, a soma dos componentes do vetor \mathbf{d} será sempre nula:

$$\begin{aligned} & (f_1^2 - f_1^1) + (f_2^2 - f_2^1) + \dots + (f_{m-1}^2 - f_{m-1}^1) + \left[\left(1 - \sum_{e=1}^{m-1} f_e^2 \right) - \left(1 - \sum_{e=1}^{m-1} f_e^1 \right) \right] = \\ & \sum_{e=1}^{m-1} f_e^2 - \sum_{e=1}^{m-1} f_e^1 + \left(1 - \sum_{e=1}^{m-1} f_e^2 \right) - \left(1 - \sum_{e=1}^{m-1} f_e^1 \right) = 0. \end{aligned} \quad (12)$$

Assumindo que os vetores de diferença \mathbf{d} , excluindo o m -ésimo componente, são observações de uma variável aleatória v -dimensional normalmente distribuída, a função densidade de \mathbf{d} toma a forma descrita na Equação 13,

$$p(\mathbf{d}) = (2\pi)^{-v/2} |\Sigma|^{-1/2} \exp\left[-\frac{1}{2}(\mathbf{d} - \boldsymbol{\mu}_d)' \Sigma^{-1} (\mathbf{d} - \boldsymbol{\mu}_d)\right] \quad (13)$$

onde $\boldsymbol{\mu}_d$ e Σ são os parâmetros vetor media e matriz covariância, respectivamente.

A densidade da distribuição normal multivariada apresenta contornos de probabilidade constante para todo \mathbf{d} , tal que $(\mathbf{d} - \boldsymbol{\mu}_d)' \Sigma^{-1} (\mathbf{d} - \boldsymbol{\mu}_d) = c^2$, onde c é uma constante (JOHNSON; WICHERN, 2007). Essa expressão, também conhecida como distância de Mahalanobis de \mathbf{d}

em relação a $\boldsymbol{\mu}_d$, descreve a superfície de um elipsóide centrado em $\boldsymbol{\mu}_d$. Os eixos de cada elipsóide têm as direções dos autovetores de $\boldsymbol{\Sigma}^{-1}$, e seus comprimentos dependem dos autovalores dessa mesma matriz. A constante c^2 , que delimita estes contornos, é definida pela distribuição Qui-quadrado com v graus de liberdade, de forma que ao escolher $c^2 = \chi_{v,\alpha}^2$, se está definindo que o volume sob o elipsóide, ou seja, a sua probabilidade, será igual a $1 - \alpha$ (Equação 14).

$$P\left[(\mathbf{d} - \boldsymbol{\mu}_d)' \boldsymbol{\Sigma}^{-1} (\mathbf{d} - \boldsymbol{\mu}_d) \leq \chi_{v,\alpha}^2\right] = 1 - \alpha \quad (14)$$

com $\chi_{v,\alpha}^2$ sendo o valor da distribuição Qui-quadrado com v graus de liberdade que concentra $100 \times (1 - \alpha)\%$ de área à esquerda (TENG et al, 2008; JOHNSON; WICHERN, 2007), conforme representado na Figura 11. Theiler et al. (2010), ao discutir a aplicação de distribuições com contornos elípticos na detecção de mudanças, afirmam que a distância de Mahalanobis pode ser usada como uma medida do nível de mudança no pixel. A utilização desta medida em estudos de detecção de mudanças pode ser creditada a Ridd e Liu (1998), no entanto esses autores deram uma abordagem diferente da adotada nesta tese, tratando a distância de Mahalanobis como uma transformação aplicada aos dados. Esta transformação foi posteriormente denominada de *Multivariate Alteration Detection* (MAD) por Nielsen, Conradsen e Simpson (1998).

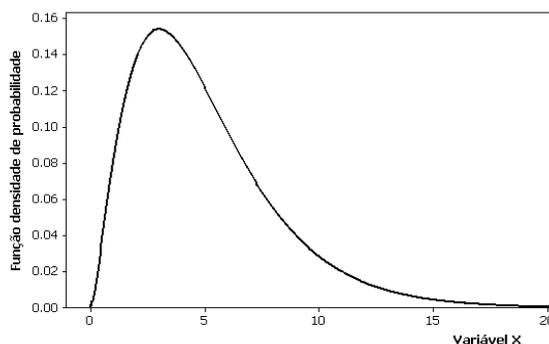


Figura 11 – Representação gráfica da função densidade de probabilidade de uma variável X que segue distribuição Qui-quadrado com $v=5$.

Como a distribuição de probabilidade da distância de Mahalanobis é conhecida sob a hipótese de normalidade e os problemas radiométricos tendem a ser minimizados nas imagens de fração, propõe-se que a detecção de mudanças seja realizada de maneira similar a um teste

de hipóteses, no qual a hipótese nula será que o vetor de diferenças médias seja nulo (Equação 15):

$$H_0: \text{sem mudanças} \rightarrow H_0: \boldsymbol{\mu}_d = \mathbf{0}. \quad (15)$$

Assim, se H_0 for verdadeira, haverá probabilidade de $1-\alpha$ de um pixel cair na região interna da elipse, elipsóide ou hiper-elipsóide formada pela distribuição conjunta dos componentes de \mathbf{d} (Figura 12), de forma que, ao cair fora dessa região, o pixel estará sinalizando uma situação de mudanças de t_1 para t_2 , ou seja, a rejeição da hipótese nula. O conceito de testes de hipóteses na detecção de mudanças foi utilizado de uma maneira similar por Teng et al. (2008), entretanto a proposta dos autores requer que a modelagem seja feita separadamente por classe e apenas uma variável foi considerada para comparação entre as datas (no caso, o NDVI). Nesta proposta, o conjunto de v frações é tomado simultaneamente (BITTENCOURT; HAERTEL, 2011), conforme exemplificado na Figura 12.

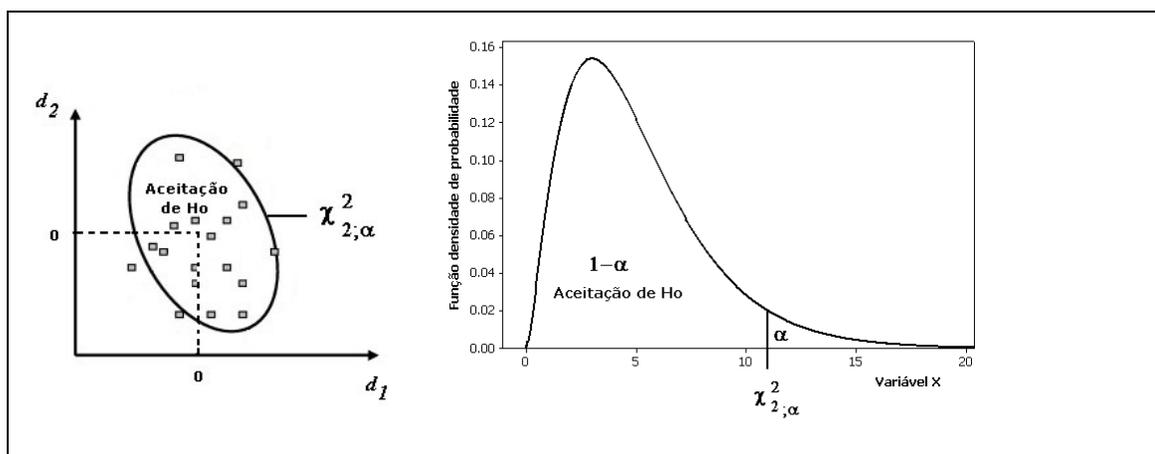


Figura 12 – Exemplo de operacionalização do conceito de detecção de mudanças proposto para $v=2$. A aceitação de H_0 é associada à classe de não-mudança.

A geração de um mapa de mudanças binário é consequência da aplicação do teste de hipóteses a todos os pixels que compõem a imagem. Para isso, consideremos que $\Omega = \{\omega_c, \omega_{nc}\}$ é um conjunto exaustivo de classes associadas aos pixels da imagem, com ω_c representando a classe de mudança e ω_{nc} a classe de não-mudança e que \mathbf{CM} é um mapa de mudanças binário que sinaliza quais os pixels de \mathbf{D} são associados à classe ω_c (Equação 16):

$$\text{CM}(i, j) = \begin{cases} 0, & \mathbf{d}(i, j)' \Sigma^{-1} \mathbf{d}(i, j) \leq \chi_{v, \alpha}^2 \\ 1, & \mathbf{d}(i, j)' \Sigma^{-1} \mathbf{d}(i, j) > \chi_{v, \alpha}^2 \end{cases} \quad (16)$$

onde $\text{CM}(i, j) = 1 \rightarrow \mathbf{d}(i, j) \in \omega_c$.

A abordagem para construção do mapa de mudanças binário **CM** é computacionalmente simples e rápida, exigindo apenas que o pesquisador escolha um nível de significância α . Deve-se ter atenção na escolha do nível de significância, pois um valor alto (e.g. 10%) pode gerar um grande número de falsos alarmes, também conhecidos como erro do tipo I. Por outro lado, a escolha de um nível muito baixo (e.g. 0,1%) pode deixar de detectar muitas mudanças importantes, gerando alarmes perdidos (erro do tipo II). Valores típicos para α são: 5% e 1% (CANTY, 2007).

Os erros do tipo I e II não podem ser eliminados dos testes de hipótese, visto que a teoria de Inferência Estatística está alicerçada na Probabilidade, entretanto, se o pesquisador utilizar este algoritmo de maneira supervisionada, é possível determinar o α ótimo por meio de uma curva ROC. Outras estratégias podem ser utilizadas para minimizar erros de classificação. Em se tratando de mapas temáticos binários, Gonzalez, Woods e Eddins (2004) apresentam um conjunto de operações morfológicas que se prestam a esse fim.

3.3.1 Introdução de informação de contexto: operações morfológicas

A realização de operações morfológicas sobre o mapa de mudanças binário **CM** é uma forma de reduzir a incidência de erros de classificação devido à inclusão de informação de vizinhança dos pixels. A utilização dessas operações com tal finalidade pode ser considerada um procedimento de filtragem, conforme descrevem Soille e Pesaresi (2002), visto que procuram remover falsos alarmes e incluir pixels perdidos no mapa de mudanças.

As operações morfológicas são definidas dentro da chamada Teoria de Morfologia Matemática, sendo amplamente aplicadas na área de Processamento de Imagens (DALLA MURA et al., 2008). A forma e o tamanho da matriz **B**, conhecida como *elemento estruturante*, controlam a saída gerada por estas operações morfológicas. Todo elemento estruturante tem uma origem que deve ser identificada, e, quando se tratar de uma matriz quadrada, a origem tende a se localizar no centro da matriz. O elemento estruturante deverá

percorrer toda a imagem binária **CM**, realizando uma operação similar às bem-conhecidas janelas móveis.

As operações de dilatação e erosão são fundamentais para o processamento morfológico de imagens, bem como a interação entre elas. A operação de dilatação tende a “aumentar” ou “engrossar” objetos em uma imagem binária. A dilatação da imagem binária **CM** por **B**, denotada por $\mathbf{CM} \oplus \mathbf{B}$, consiste da expansão dos elementos da matriz **CM**, seguindo a forma de **B**, sempre que houver $CM(i,j)=1$ na posição correspondente à origem do elemento estruturante. A operação de erosão, por sua vez, tem a função de “encolher” ou “afinar” objetos, de acordo com o elemento estruturante. A erosão de **CM** por **B**, denotada por $\mathbf{CM} \ominus \mathbf{B}$, impõe $CM(i,j)=0$ na posição correspondente a origem de **B**, sempre que a forma definida no elemento estruturante não for encontrada na imagem binária **CM** (GONZALEZ; WOODS; EDDINS, 2004).

As operações de erosão e dilatação são frequentemente utilizadas em conjunto em aplicações de processamento de imagens. Dentre essas combinações, as operações de abertura e fechamento (*opening and closing*) são comumente aplicadas. A abertura de **CM** por **B**, denotada por $\mathbf{CM} \circ \mathbf{B}$, nada mais é do que a erosão de **CM** por **B**, seguida da dilatação do resultado por **B** (Equação 17).

$$\mathbf{CM} \circ \mathbf{B} = (\mathbf{CM} \ominus \mathbf{B}) \oplus \mathbf{B} \quad (17)$$

A operação de fechamento de **CM** por **B**, denotada por $\mathbf{CM} \bullet \mathbf{B}$, é uma dilatação seguida de uma erosão (Equação 18).

$$\mathbf{CM} \bullet \mathbf{B} = (\mathbf{CM} \oplus \mathbf{B}) \ominus \mathbf{B} \quad (18)$$

A escolha do elemento estruturante depende dos objetivos do pesquisador. Como o principal objetivo da aplicação de operadores morfológicos sobre o mapa binário **CM** é o de filtragem, dois elementos estruturantes foram escolhidos, **B₄** e **B₈**, motivados pela conectividade entre o pixel central (origem) e a sua vizinhança (Equação 19). Pixels localizados fora dessas matrizes não são contíguos com o pixel central e, por isso, não foram considerados.

$$\mathbf{B}_4 = \begin{bmatrix} & 1 & \\ 1 & [1] & 1 \\ & 1 & \end{bmatrix} \quad \text{e} \quad \mathbf{B}_8 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & [1] & 1 \\ 1 & 1 & 1 \end{bmatrix}. \quad (19)$$

Operadores morfológicos com elementos estruturantes semelhantes foram utilizados por Chou et al. (1994) e Simpsons (1992). O efeito dessas operações é o de simplificar o mapa binário **CM** originalmente gerado, removendo o efeito *salt-and-pepper* e, ao mesmo tempo, preservando estruturas de interesse e características geométricas (DALLA MURA et al., 2008; GONZALEZ; WOODS; EDDINS, 2004). Para efeitos de notação, o mapa de mudanças binário já submetido a uma operação de filtragem morfológica será genericamente denotado por **CM'**.

3.3.2 Classes de Mudanças

A construção de um mapa de mudanças binário (**CM**) não traz informação sobre os tipos de alteração que ocorreram na superfície terrestre de t_1 para t_2 . No entanto, como o conjunto de variáveis que forma a imagem de diferenças de fração tem um significado físico, é possível interpretá-lo de uma maneira direta, particionando o espaço de diferenças ou, até mesmo, aplicando um algoritmo de agrupamento sobre os resultados. Hartel, Shimabukuro e Almeida-Filho (2004) aplicaram o algoritmo de *clustering Isodata* sobre um conjunto de variáveis derivado da imagem de diferenças de fração, o que exigiu grande esforço dos pesquisadores na interpretação dos resultados, pois os *clusters* associados à classe não-mudança (ω_{nc}) misturaram-se àqueles associados às classes de mudança (ω_{ci}).

Para solucionar este problema, Bittencourt e Haertel (2011) sugeriram que a análise de agrupamento seja aplicada sobre a imagem-produto entre o mapa de mudanças binário e a imagem de diferenças (**CM*D**). Esse procedimento faz com que apenas os pixels considerados significativos sejam incluídos na análise de agrupamento, o que produz um mapa final mais “limpo”. Para melhorar os resultados, propõe-se que o mapa binário gerado após a filtragem morfológica seja utilizado, isto é, que a análise de agrupamento seja realizada sobre a imagem-produto (**CM'*D**).

A simples partição do espaço de diferenças de fração em quadrantes, octantes ou, genericamente, 2^y regiões, facilita a interpretação dos resultados, conforme representado na Figura 13, ao delimitar as regiões de acordo com o sinal das diferenças.

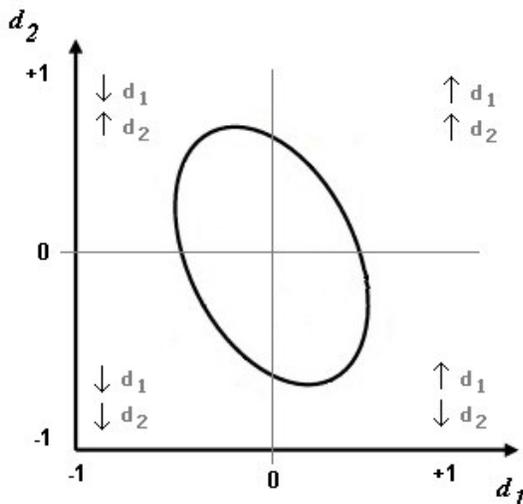


Figura 13 – Representação da partição do espaço de diferenças de fração para o caso bidimensional ($v=2$)

Outra maneira de particionar o espaço de diferenças de fração se dá pela utilização de algoritmos de agrupamento. De acordo com Jain (2010), o algoritmo K -médias é, de longe, o mais popular, tendo uma história rica e que conta com aplicações em diferentes áreas do conhecimento. Ainda segundo Jain (2010), o algoritmo K -médias foi descoberto de maneira independente por pesquisadores de diferentes áreas, entretanto muitos creditam a MacQueen (1967) sua autoria.

No algoritmo K -médias, o erro quadrático (EQ) de um grupo é definido, de uma forma geral, pela Equação 20, na qual x_i representa um vetor de observações, μ_k , a média do k -ésimo *cluster* e $C=\{c_1, \dots, c_K\}$ representa o conjunto de K *clusters*.

$$EQ(c_k) = \sum_{x_i \in c_k} \|x_i - \mu_k\|^2 \quad (20)$$

O objetivo do algoritmo é minimizar a Equação 21, ou seja, a soma do erro quadrático sobre todos os K grupos ($EQ(C)$).

$$EQ(C) = \sum_{k=1}^K \sum_{x_i \in c_k} \|x_i - \mu_k\|^2 \quad (21)$$

As etapas que compõem o algoritmo K -médias podem ser sintetizadas da seguinte forma:

1. Escolha de um valor para K ($K \geq 2$) e rotulagem de todos os x_i em um dos *clusters*;
2. Cálculo dos valores de μ_k ($k=1, \dots, K$)

3. Atribuição das observações x_i ao cluster mais próximo, seguindo uma métrica de distância em relação à μ_k .
4. Retorno a 2ª etapa até que não haja mais trocas de *cluster*.

A idéia central do algoritmo *K*-médias foi estendida de diferentes maneiras. Dentre elas, destaca-se o algoritmo *Isodata*, no qual o número de *clusters* pode ser automaticamente ajustado durante o processo iterativo através da fusão de clusters com vetores média similares e da divisão de *clusters* com grande variabilidade interna (JENSEN, 1996). Apesar dessa vantagem do *Isodata* sobre o *K*-médias, optou-se por esse último por ser computacionalmente mais simples e, ainda, pelo fato de que ambos produziram resultados quase idênticos em um estudo exploratório.

O produto final da análise de agrupamento é um mapa temático, o qual identifica as classes de mudança facilmente interpretáveis a partir do conhecimento do valor dos vetores de média dos *clusters*, também conhecidos como centróides.

3.3.3 Resumo da proposta rígida

A Figura 14 apresenta um fluxograma das etapas que compõem a proposta de classificador rígido para detecção de mudanças.

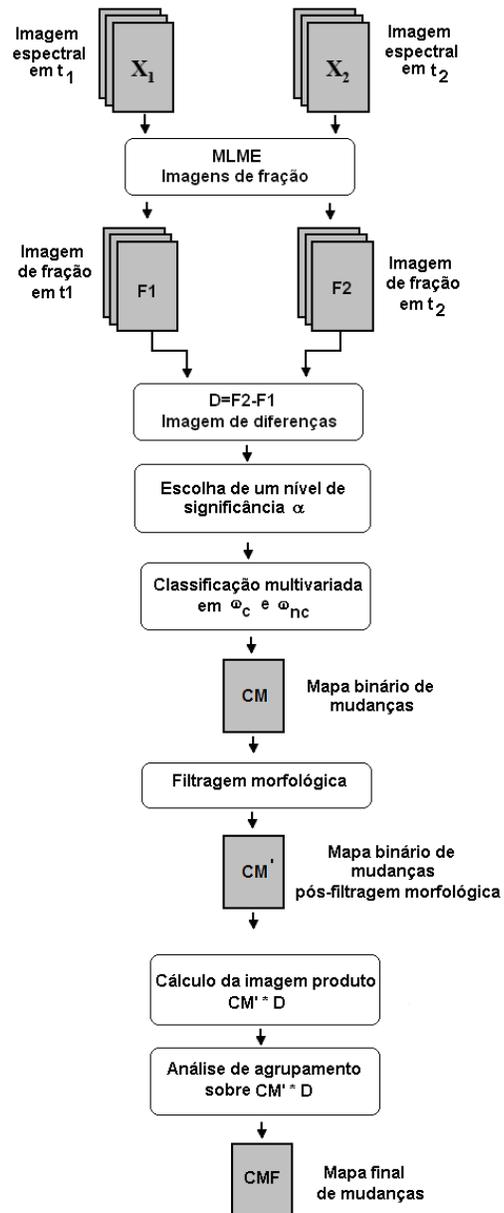


Figura 14 – Fluxograma do classificador rígido para detecção de mudanças

O algoritmo inicia com a geração das imagens de fração a partir das imagens espectrais e segue com a produção da imagem de diferença **D**. A partir da escolha de um nível de confiança, procede-se a geração de um mapa de mudanças binário **CM**, o qual é submetido a um procedimento de filtragem, gerando o mapa **CM'**. Por fim, calcula-se a imagem-produto **CM'*D** sobre a qual é realizada a análise de agrupamento para, então, gerar o mapa final de mudanças (**CMF**).

3.4 PROPOSTA DE UM CLASSIFICADOR SUAVE PARA DETECÇÃO DE MUDANÇAS

Uma maneira de flexibilizar os resultados da classificação rígida é através da aplicação da regressão logística, uma técnica estatística que relaciona, em sua forma tradicional, um conjunto de variáveis independentes a uma variável dependente binária (HOSMER; LEMESHOW, 2000).

O principal problema da regressão logística é a necessidade de amostras de treinamento para a sua execução, caracterizando um procedimento supervisionado. Uma saída para automatizar o processo, sem necessidade de seleção de amostras de treinamento, é a utilização de uma amostra aleatória de pixels da própria imagem binária \mathbf{CM} para compor a variável dependente binária do modelo logístico. Assim, o módulo da imagem de diferenças pode formar o conjunto de v variáveis independentes.

O modelo logístico permite estimar diretamente a probabilidade de ocorrência de um evento por meio da Equação 22, o que configura um procedimento de classificação suave (CHENG; VARSHNEY; ARORA, 2006; BITTENCOURT; MORAES; HAERTEL, 2007).

$$P(\omega_c | \mathbf{d}) = \frac{\exp(\beta_0 + \boldsymbol{\beta}' \mathbf{d})}{1 + \exp(\beta_0 + \boldsymbol{\beta}' \mathbf{d})} \quad (22)$$

onde β_0 e $\boldsymbol{\beta}' = [\beta_1, \dots, \beta_v]$ são parâmetros a serem estimados.

De acordo com McLachlan (1992) e Bittencourt et al. (2009), o modelo de regressão logística pode ser considerado um procedimento parcialmente paramétrico visto que apenas o logaritmo da razão entre a probabilidade de ocorrência e não ocorrência de um evento estão sendo modelados (Equação 23).

$$\ln \left(\frac{P(\omega_c | \mathbf{d})}{P(\omega_{nc} | \mathbf{d})} \right) = \beta_0 + \boldsymbol{\beta}' \mathbf{d} \quad (23)$$

O modelo de regressão logística assume que a soma das probabilidades dos eventos ω_c e ω_{nc} seja unitária: $P(\omega_c) + P(\omega_{nc}) = 1$. Assim, a tarefa do modelo pode ser expressa pela Equação 24, ou seja, a probabilidade de pertencer à classe ω_c é obtida através do modelo a partir do conhecimento do vetor de diferenças de fração \mathbf{d} .

$$\mathbf{d} \rightarrow P(\omega_c | \mathbf{d}) \in [0, 1]. \quad (24)$$

Graficamente, a relação entre um componente do vetor \mathbf{d} , digamos d_i , e a probabilidade de pertencer à classe ω_c descreve o característico formato de “S” (HOSMER; LEMESHOW, 2000; BITTENCOURT, 2001). Como as variáveis que compõem a imagem de diferenças de frações variam no intervalo $[-1,1]$, sendo os extremos associados à mesma classe ω_c , deve-se tomar o módulo das diferenças antes de proceder com a regressão logística (Figura 15).

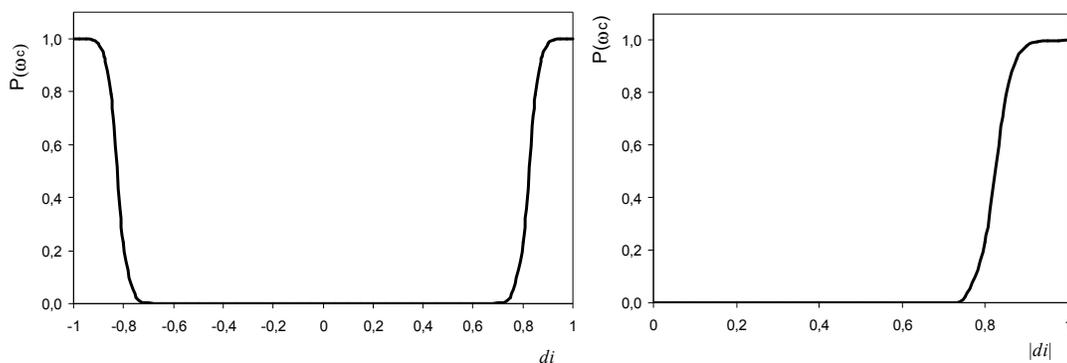


Figura 15 – Exemplo da probabilidade de pertencer à classe ω_c estimada pelo modelo de regressão logística como função de uma única componente d_i da imagem de diferenças de fração.

Os parâmetros do modelo de regressão logística são estimados pelo método da máxima verossimilhança. Como o sistema de equações a ser solucionado é não-linear, métodos computacionais numéricos são necessários. Bittencourt (2001) utilizou o procedimento CATMOD, disponível no pacote estatístico SAS[®], para estimação dos parâmetros. Neste estudo foi utilizada a função MNRFIT disponível em ambiente Matlab[®], a qual permite modelar a regressão logística binária tradicional e variações que incluem a regressão logística politômica e ordinal.

A Figura 16 apresenta, na forma de um fluxograma, o conjunto de etapas do classificador suave.

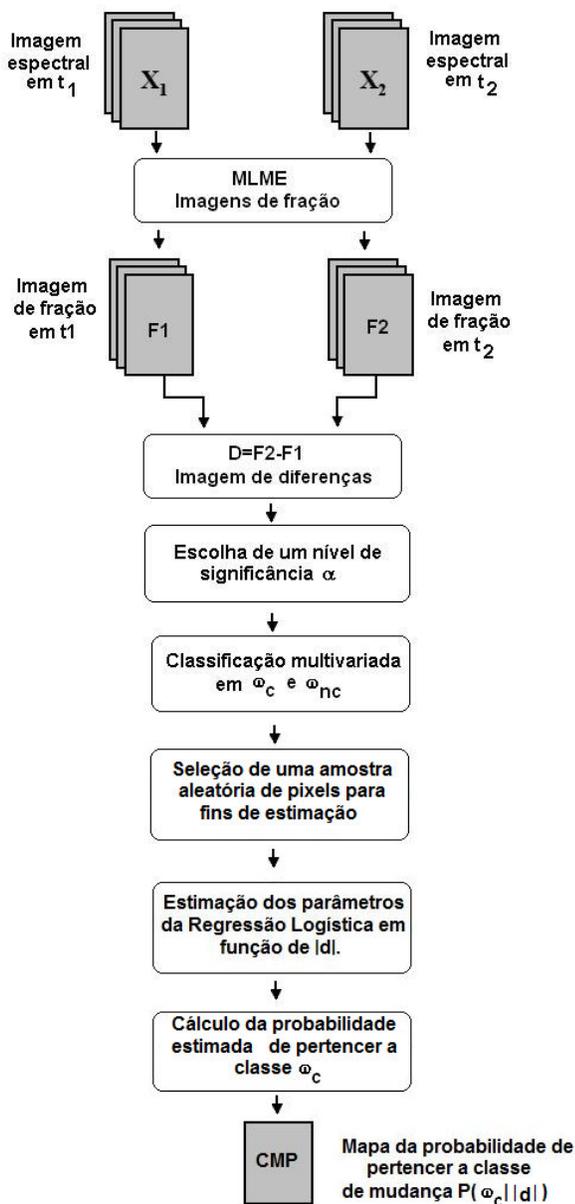


Figura 16 - Fluxograma do classificador suave para detecção de mudanças aplicando regressão logística

O procedimento suave segue os mesmos passos do classificador rígido até a classificação multivariada em ω_c ou ω_{nc} . Após binarizar a imagem, uma amostra aleatória de pixels é selecionada para estimação dos parâmetros do modelo logístico, o qual será responsável pela suavização dos resultados. Nesta etapa, as diferenças são tomadas em módulo. O algoritmo culmina com a geração do mapa das probabilidades $P(\omega_c||d|)$, denominado **CMP**.

3.5 PROPOSTA DE UM CLASSIFICADOR *FUZZY* PARA DETECÇÃO DE MUDANÇAS

A maior parte dos procedimentos para classificação de imagens digitais pode ser considerada rígida por considerar cada pixel da imagem como uma entidade “pura”. Isso significa que a área correspondente a um pixel na superfície terrestre é rotulada a uma única classe (ver seção 3.2). Posto que os sinais elétricos registrados pelo sensor indicam o nível de radiância médio da área correspondente a um pixel na superfície terrestre e que, em sensores de média e alta resolução espacial, há alvos que ocupam área inferior ao tamanho do pixel, é razoável supor que haja mais de uma classe presente em uma grande quantidade de pixels da imagem (BITTENCOURT; HAERTEL, 2009).

A constatação de que um conjunto de alvos ocupa um mesmo pixel permite supor que mudanças entre duas imagens possam ocorrer em nível de subpixel. Baseados nisso, Bittencourt e Haertel (2009) apresentaram uma proposta *bayesiana* que permitiu detectar mudanças em nível de subpixel, permitindo a implementação de critérios do tipo *fuzzy*, eliminando, desta forma, a necessidade de uma definição rígida de duas classes mutuamente excludentes (ω_c : mudança, ω_{nc} : não-mudança). Zanotta (2010), valendo-se do mesmo conceito, aperfeiçoou a proposta, incorporando informações de contexto espacial via relaxação probabilística.

A proposta *fuzzy* parte da definição de que o conjunto de classes $\Omega = \{\omega_c, \omega_{nc}\}$ pode ser suavizado ou flexibilizado por meio do cálculo de graus de pertinência às classes ω_c e ω_{nc} . Assim, diferentemente da regressão logística, não é a probabilidade de ocorrência da classe ω_c que é estimada, mas sim o nível interno de mudança no pixel. Como as duas classes são complementares, o conhecimento do grau de pertinência a uma das classes é suficiente. O cálculo dos graus de pertinência a ω_c pode ser realizado de diferentes maneiras. Uma delas é a proposta de Wang (1990), na qual é necessário assumir modelos probabilísticos subjacentes às classes de Ω e estimar os respectivos parâmetros, para, assim, estabelecer a função de decisão $G_i(\mathbf{d})$. Assumindo que a distribuição das diferenças nas classes ω_c e ω_{nc} sejam gaussianas – o que é razoável para sensores passivos (BRUZZONE; PRIETO, 2000) –, a função de decisão assume a forma da Equação 25.

$$G_i(\mathbf{d}) = p(\mathbf{d} | \omega_i)P(\omega_i) = \left\{ (2\pi)^{-v/2} |\hat{\Sigma}_i|^{-1/2} \exp\left[-\frac{1}{2}(\mathbf{d} - \hat{\mu}_i)' \hat{\Sigma}_i^{-1} (\mathbf{d} - \hat{\mu}_i)\right] \right\} P(\omega_i) \quad (25)$$

$i = c, nc$

Os graus de pertinência às classes, denotados por w_i , podem ser diretamente estimados pela razão entre as funções de decisão, conforme a Equação 26, extraída de Wang (1990):

$$w_i = \frac{G_i(\mathbf{d})}{G_c(\mathbf{d}) + G_{nc}(\mathbf{d})} \quad \text{onde } i = c, nc. \quad (26)$$

É fácil perceber que $0 \leq w_i \leq 1$, tornando possível a construção de uma imagem unidimensional formada pelos graus de pertinência a uma das classes.

Ao admitir que funções de probabilidade referentes às classes ω_c e ω_{nc} são gaussianas, o conjunto de parâmetros θ a ser estimado será constituído pelos elementos do conjunto da Equação 27.

$$\theta = \{P(\omega_c), P(\omega_{nc}), \mu_c, \mu_{nc}, \Sigma_c, \Sigma_{nc}\} \quad (27)$$

onde,

$P(\omega_c)$: probabilidade *a priori* de pertencer à classe de mudança ω_c

$P(\omega_{nc})$: probabilidade *a priori* de pertencer à classe não-mudança ω_{nc}

μ_c e μ_{nc} : vetores média das classes mudança e não-mudança

Σ_c e Σ_{nc} : matrizes covariância das classes mudança e não-mudança.

Zanotta (2010) estimou os parâmetros de θ através do algoritmo *Expectation Maximization* (EM), proposto por Dempster, Laird e Rubin (1977), utilizando a metodologia proposta por Bittencourt e Haertel (2009) para obtenção de estimativas iniciais. A idéia de utilizar o algoritmo EM sobre problemas de detecção de mudanças pode ser creditada a Bruzzone e Prieto (2000), entretanto foi Zanotta (2010) que a utilizou originalmente sobre imagens de fração. Apesar de os resultados encontrados por esses autores serem encorajadores, os experimentos sobre imagens de fração relatam que a diferença entre as densidades pode ser creditada quase que exclusivamente aos parâmetros de forma (matriz covariância). Os vetores de médias das funções densidade subjacentes às classes ω_c e ω_{nc} resultaram muito próximos, conforme mostra a Figura 17.

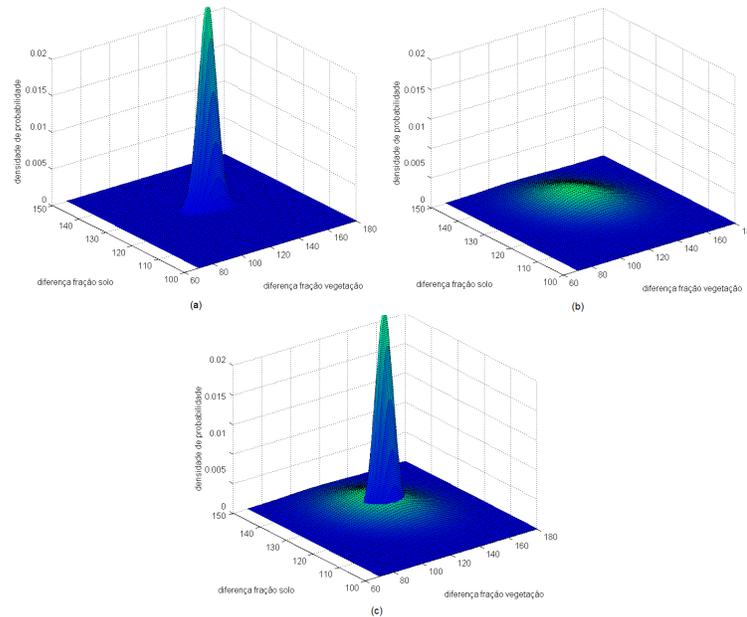


Figura 17 – Funções densidade normais multivariadas representativas das classes ω_c e ω_{nc} .

Fonte: Zanotta (2010).

A constatação de que os vetores de médias pouco contribuem para a discriminação entre as classes e, somando-se a isso, a busca de uma proposta *fuzzy* que estivesse relacionada às duas anteriores levaram à proposta descrita na subseção a seguir.

3.5.1 Fuzzificação via Distância de Mahalanobis

A distância de Mahalanobis segue uma distribuição de probabilidade conhecida: Qui-quadrado com v graus de liberdade, onde v é a dimensionalidade do problema. Adicionando a hipótese nula de que não há alteração entre as imagens coletadas em t_1 e t_2 ($H_0: \boldsymbol{\mu}_d = \mathbf{0}$), a expressão toma a forma da Equação 28,

$$\Delta^2 = \mathbf{d}'\boldsymbol{\Sigma}^{-1}\mathbf{d} \sim \chi_v^2 \quad (28)$$

onde $\Delta^2 = 0$ é o ponto ideal de aceitação de H_0 e $\Delta^2 = \infty$ é o ponto ideal de rejeição de H_0 . Isso significa que, à medida que aumenta a distância de Mahalanobis, aumenta também a plausibilidade à rejeição de H_0 . Assim, propõe-se que o grau de pertinência a ω_c , denotado por w_c , seja calculado diretamente pela função de distribuição acumulada de Δ^2 , conforme mostra a Equação 29,

$$w_c = P(\Delta^2 \leq \delta) = F(\delta) = \frac{1}{2^{v/2} \Gamma(v/2)} \int_{-\infty}^{\delta} \delta^{\frac{v}{2}-1} e^{-\delta/2} d\delta \quad (29)$$

onde

$v = 1, 2, 3, \dots$; $\delta \in [0; \infty)$ e Γ é a função Gama (ver Apêndice I)

Graficamente, o grau de pertinência à classe ω_c corresponde à área sob a função densidade de probabilidade acumulada até o ponto δ (Figura 18). Jurkovic (2006) afirma que, mesmo que a função de pertinência a um conjunto *fuzzy* seja uma medida “não-estatística”, isso não significa que não se possam utilizar funções densidade de probabilidade para atribuição de graus de pertinência.

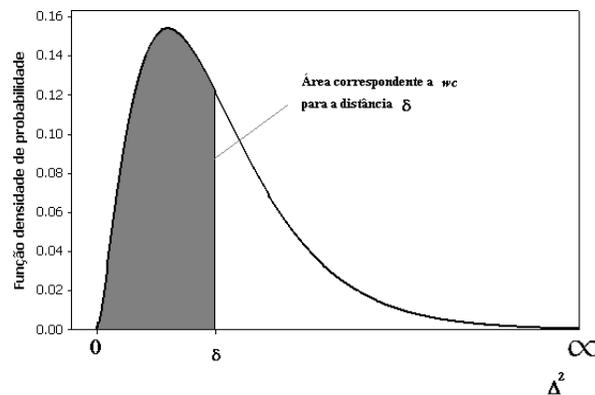


Figura 18 – Representação gráfica do cálculo de w_c – grau de pertinência à classe ω_c – por meio da função de distribuição acumulada do modelo Qui-quadrado.

Apesar de a distribuição Qui-quadrado representar satisfatoriamente o comportamento probabilístico de Δ^2 , a forma de sua distribuição acumulada, especialmente para um número pequeno de graus de liberdade, faz com que baixos valores de Δ^2 levem a graus de pertinência elevados, muitas vezes incompatíveis com a realidade. A Figura 19 mostra a distribuição acumulada da Qui-quadrado para três diferentes graus de liberdade.

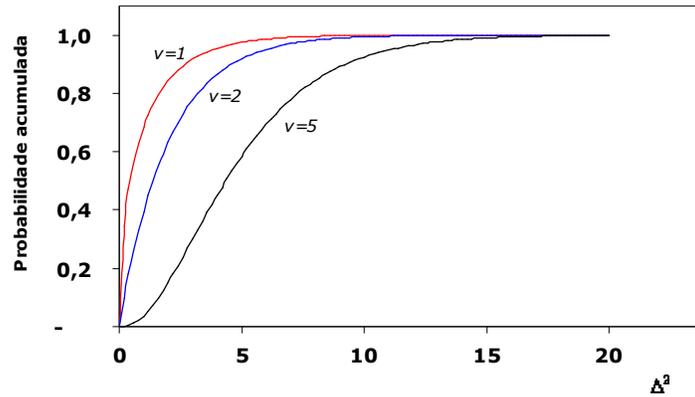


Figura 19 – Função de distribuição acumulada do modelo Qui-quadrado para três diferentes graus de liberdade (v).

Uma maneira de tornar o grau de pertinência de um pixel dependente de seu contexto e, ao mesmo tempo, induzi-lo a dirigir-se a um dos valores extremos de w_c (0 e 1) pode ser realizada por meio de uma operação inspirada no operador *fuzzy* de concentração. Enquanto a clássica operação *fuzzy* da concentração (TSO; MATHER, 2009) se dá elevando os graus de pertinência ao quadrado, propõe-se que o grau de pertinência de um pixel seja obtido pelo produto de seu próprio grau de pertinência e os de seus vizinhos contíguos (Equações 30 e 31). Os dois esquemas de vizinhança utilizados são iguais aos já apresentados na Equação 19.

Esquema com 4 vizinhos:

	$(i-1, j)$	
$(i, j-1)$	(i, j)	$(i, j+1)$
	$(i+1, j)$	

$$w_c^{(4)}(i, j) = \left[\prod_{q=-1}^1 w_c(i+q, j) \right] \times w_c(i, j-1) \times w_c(i, j+1) \quad (30)$$

$$\text{nde } q \in \{-1, 0, +1\}$$

Esquema com 8 vizinhos:

$(i-1, j-1)$	$(i-1, j)$	$(i-1, j+1)$
$(i, j-1)$	(i, j)	$(i, j+1)$
$(i+1, j-1)$	$(i+1, j)$	$(i+1, j+1)$

$$w_c^{(8)}(i, j) = \prod_{q=-1}^1 \prod_{r=-1}^1 w_c(i+q, j+r) \quad (31)$$

$$\text{onde } q, r \in \{-1, 0, +1\}$$

A concentração dos graus de pertinência ocorre porque valores elevados de w_c decaem menos do que valores pequenos quando submetidos ao produtório. A Figura 20 ilustra os graus de pertinência resultantes pelos dois esquemas – $w_c^{(4)}$ e $w_c^{(8)}$ – como função de w_c , sob a condição de que todos os graus de pertinência da vizinhança sejam iguais. Essa suposição é necessária para tornar possível a representação gráfica no plano, visto tratar-se de um problema em alta dimensionalidade.

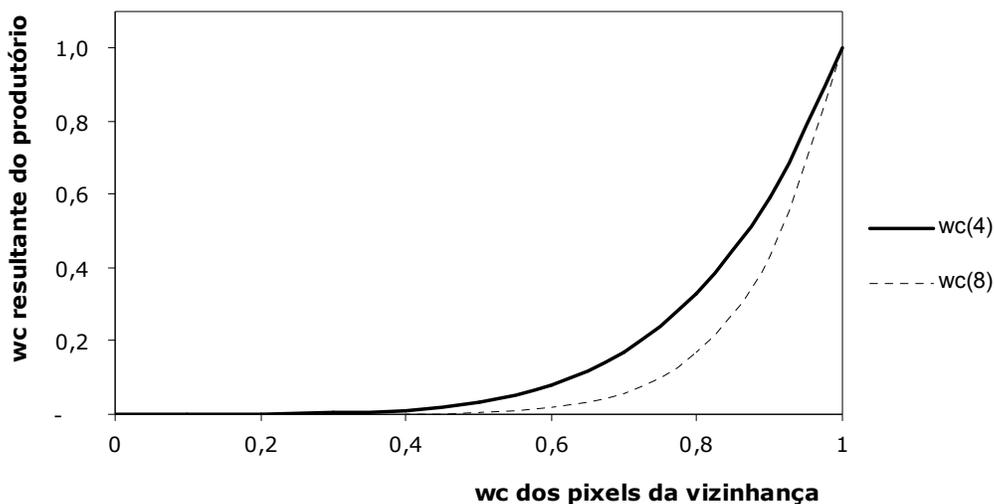


Figura 20 – Valores de $w_c^{(4)}$ e $w_c^{(8)}$ como função de w_c em situações nas quais todos os graus de pertinência da vizinhança são iguais

Percebe-se que graus de pertinência baixos deverão concentrar-se em torno do valor zero, quando submetidos ao produtório e, como a função é crescente a taxas crescentes, os graus de pertinência mais elevados deverão ser menos afetados, entretanto deverão apresentar maior variabilidade.

As etapas necessárias para aplicação da proposta *fuzzy* são sintetizadas na Figura 21, cujo produto final é um mapa de graus de pertinência à classe de mudança.

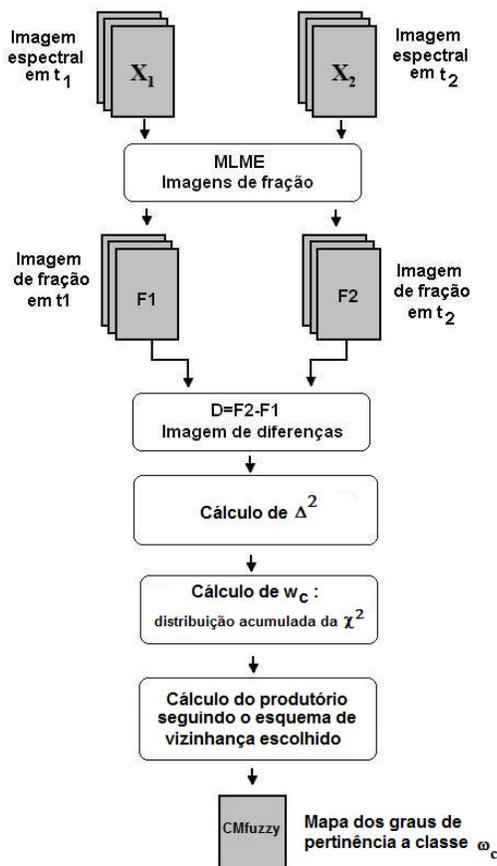


Figura 21 – Fluxograma do classificador *fuzzy* para detecção de mudanças a partir da distância de Mahalanobis

3.6 RECURSOS COMPUTACIONAIS

No que se refere à parte computacional (*software*), os programas utilizados para execução deste trabalho tiveram três propósitos: pré-processamento, implementação e visualização. As atividades de pré-processamento das imagens foram executadas no ENVI[®] versão 4.2 e consistiram de correções radiométricas e de registro. O Matlab[®] foi utilizado para geração das imagens de fração (Apêndice B.1) e para desenvolvimento de todas as rotinas computacionais relacionadas às propostas descritas nas seções anteriores desse capítulo (Apêndices B.2 até B.4). Foram utilizadas funções já disponibilizadas na biblioteca do programa e algoritmos especialmente criados para os propósitos desta tese.

Sempre que possível, optou-se por operações vetoriais em vez de sequenciais para minimizar o tempo de processamento. Apesar de o Matlab[®] permitir a visualização de

imagens, o programa Multispec[®] versão 3.1 também foi utilizado para esse fim, por razões de praticidade.

Todas as imagens utilizadas foram convertidas para o formato Erdas.74, o que permitiu intercâmbio direto entre os três *softwares* supracitados.

Em relação ao *hardware*, foram utilizados computadores pessoais com processadores Intel Core2Duo[®], 2.40GHz e 3Gb de memória RAM, os quais operam sob plataforma Windows[®] de 32bits.

4. EXPERIMENTOS

Os cinco experimentos realizados foram divididos em dois grupos, de acordo com o tipo das imagens utilizadas: sintéticas ou reais. Dois experimentos com imagens sintéticas e três com imagens reais foram conduzidos. Os experimentos com imagens sintéticas permitiram o cálculo de todas as medidas apresentadas na seção 2.8, o que só teria sido possível com as imagens reais, se a verdade terrestre fosse conhecida em t_1 e em t_2 .

Os experimentos realizados sobre imagens sintéticas apresentam sequencialmente os seguintes elementos:

- a) cena original e recorte efetivamente utilizado no experimento;
- b) imagem de fração;
- c) imagens de diferença com adição de crescentes níveis de ruído gaussiano;
- d) mapa de referência;
- e) mapas de mudança binários resultantes da proposta rígida;
- f) indicadores quantitativos referentes à proposta rígida;
- g) indicadores quantitativos de desempenho;
- h) curvas ROC e representação gráfica do coeficiente $kappa$;
- i) mapa temático das classes de mudança;
- j) mapas de probabilidade resultantes da proposta de classificador suave e/ou histograma(s);
- k) mapas de grau de pertinência resultantes da proposta *fuzzy* e/ou histogramas.

Os três experimentos conduzidos sobre imagens reais seguem as mesmas etapas, porém o desconhecimento do mapa de referência (d) impossibilita o cálculo das medidas quantitativas, inviabilizando as etapas (f), (g) e (h).

O Quadro 3 apresenta algumas importantes características das imagens utilizadas nos experimentos. Uma nomenclatura foi atribuída aos experimentos com o propósito de facilitar a referência aos mesmos: S1 e S2 para os dois experimentos com imagens sintéticas; R1, R2 e R3 para os três experimentos com imagens reais.

Quadro 3 – Características das imagens utilizadas nos experimentos

<i>Tipo</i>	<i>Nome</i>	<i>Satélite / Sensor</i>	<i>Órbita ponto</i>	<i>Data de aquisição</i>	<i>Mudanças inseridas</i>	<i>Tipo de Ruído / SNR</i>	<i>Erro de registro</i>
Sintéticos	S1	Landsat 5 – TM	220/81	30/11/1994	- Aterro na lagoa - Inserção de açude - Desmatamento	Gaussiano 10 – 40dB	Não há
	S2	Landsat 5 – TM	221/81	03/02/2007	- Mudanças graduais - Áreas não retangulares.	Gaussiano 05 – 15dB	Não há
<i>Tipo</i>	<i>Nome</i>	<i>Satélite / Sensor</i>	<i>Órbita ponto</i>	<i>Datas de aquisição</i>	<i>Mudanças percebidas</i>	<i>Correção radiométrica</i>	<i>Erro de registro</i>
Reais	R1	Landsat 5 – TM	221/81	01/10/2007 06/02/2008	- Inundação - Dinâmica de uso do solo	Equalização de histogramas	0,35 pixel
	R2	Landsat 5 – TM	233/57	11/1994 01/1996	- Atv. de mineração - Desmatamento	Ajuste de histogramas (<i>matching</i>)	0,80 pixel
	R3	Landsat 5 – TM	220/ 78 e 79	04/06/2007 01/02/2009	- Dinâmica de uso do solo - Cicatrizes de movimentos de massa	Ajuste de histogramas (<i>matching</i>)	0,40 pixel

4.1 EXPERIMENTOS COM IMAGENS SINTÉTICAS

4.1.1 Experimento S1

O experimento S1 consiste de um recorte de 1001×1001 pixels da cena correspondente à órbita 220, ponto 21, do sistema sensor Landsat-TM (Figura 22). De um total de sete bandas espectrais disponibilizadas, seis foram utilizadas, ficando ausente apenas a banda correspondente à faixa termal, devido à menor resolução espacial.

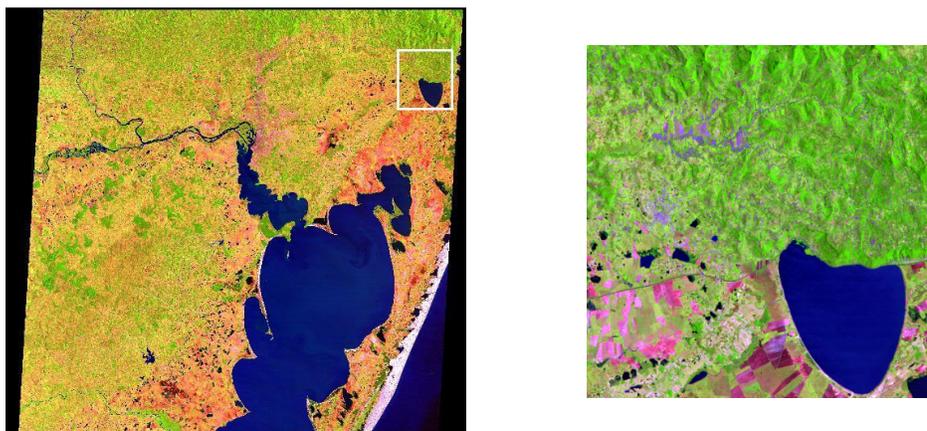


Figura 22 – Cena Landsat-TM correspondente à órbita-ponto 220/81 e detalhe do recorte efetivamente utilizado no experimento S1

A área do recorte abrange parte dos municípios de Santo Antônio da Patrulha, Osório e Caraá, nordeste do estado do Rio Grande do Sul. A região caracteriza-se pela presença de seis unidades geomorfológicas segundo o IBGE (2003): Planície Lagunar, Planície Litorânea Interna, Planície Alúvio-Coluvionar, Planalto Serra Geral, Patamares da Serra Geral e Depressão do Rio Jacuí. O uso do solo e cobertura da terra é caracterizado pela presença de grandes áreas agrícolas associadas a lavouras de arroz/solo exposto e corpos hídricos representados por açudes e pela Laguna dos Barros em áreas de planície situadas ao sul da cena. Ocorre também uma pequena mancha urbana associada ao município de Santo Antônio da Patrulha e uma extensa e densa faixa de cobertura florestal em áreas com altitudes e declividade mais elevadas situadas no planalto ao norte da cena.

Para geração das imagens de fração, três *endmembers* foram considerados – vegetação, solo exposto e água – conforme já apresentado na Figura 10, no Capítulo 3. As imagens de diferença foram criadas pela operação de subtração entre as imagens ruidosas adicionadas das regiões de mudança e a imagem original, conforme mostra a Figura 23.

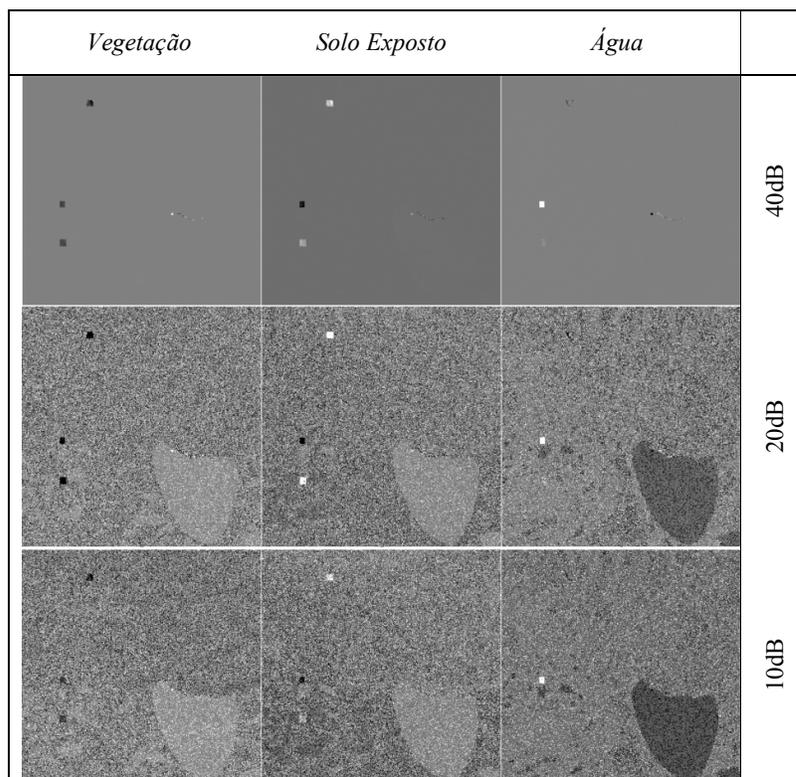


Figura 23 – Conjunto de imagens de diferença de fração do experimento S1 contaminadas com três níveis de ruído gaussiano (SNR=40dB, 20dB e 10dB).

As cinco regiões de mudança inseridas durante o processo de geração da imagem sintética foram extraídas da própria imagem. Elas representam possíveis alterações de paisagem na cena em questão: desmatamento, preparação de área para cultivo, criação de um açude e aterro. A Figura 24 apresenta o mapa de referência binário (CM_{Ref}) que identifica os tipos de mudanças inseridos.

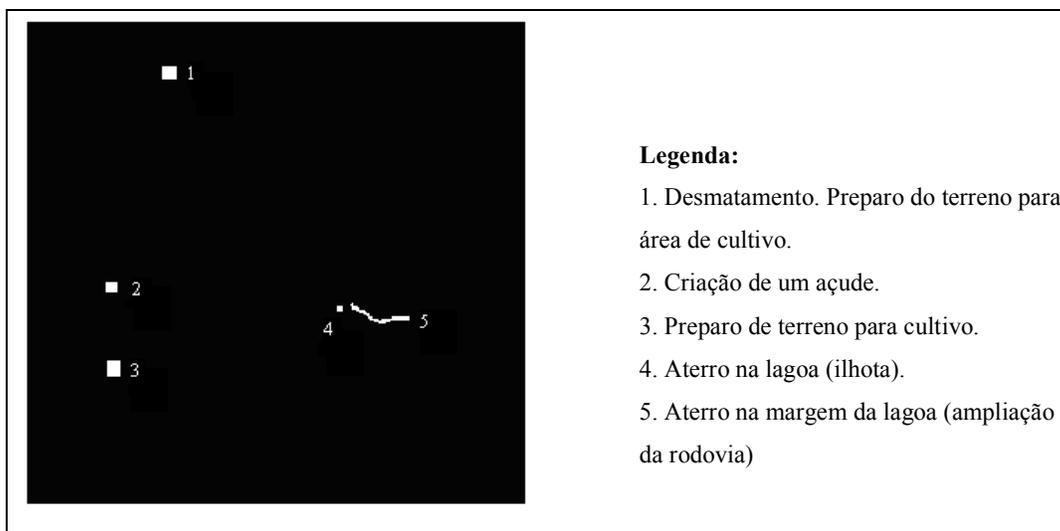


Figura 24 – Localização das alterações de paisagem inseridas para geração da imagem sintética do experimento S1: mapa de referência.

O primeiro desafio do experimento S1 foi a identificação das regiões apresentadas na Figura 24 de forma automática por meio do classificador rígido. Neste classificador, a única intervenção do analista deu-se na escolha do nível de significância. As Figuras 25 e 26 apresentam os resultados para três faixas de SNR, considerando o classificador sem e com filtragem morfológica separadamente para os níveis de confiança ($1-\alpha$) de 95 e 99,74%.

Os mapas de mudança revelam que, em situações nas quais o sinal se sobrepõe muito ao ruído ($SNR=40dB$), não existe a necessidade de filtragem morfológica. Por outro lado, à medida que a intensidade do sinal diminui ($SNR \leq 20dB$), a filtragem passa a ser fundamental para exclusão dos falsos alarmes. Um problema que surge na filtragem morfológica, especialmente se associada a altos níveis de confiança, é a corrosão das bordas nas regiões de mudança. Esse fenômeno ocorreu na imagem com $SNR=10dB$ associada a $(1-\alpha)=99,74\%$. O processo de filtragem pode até causar a eliminação de áreas de mudanças, se a dimensão das mesmas for reduzida.

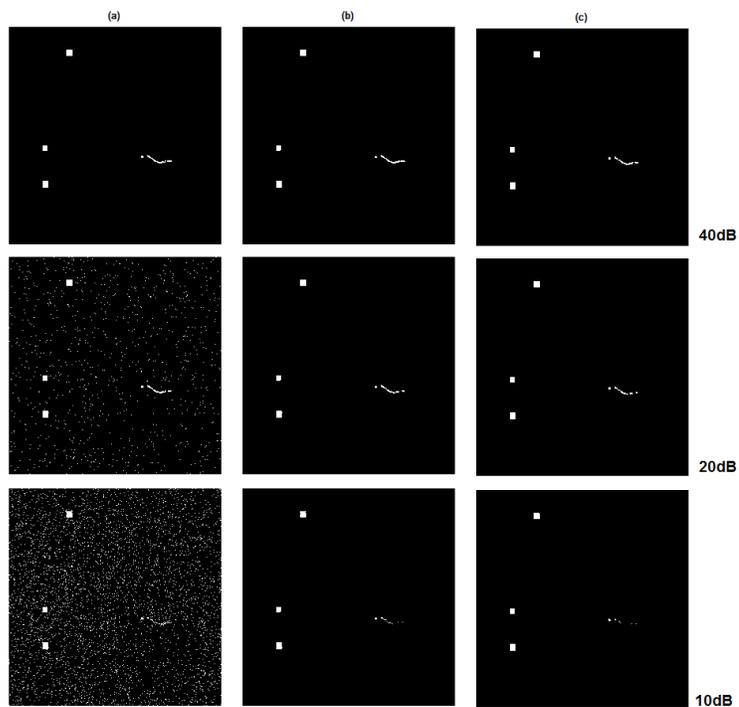


Figura 25 – Mapas de mudança resultantes da proposta rígida com $(1-\alpha)=95\%$: (a) sem filtragem, (b) com filtragem morfológica utilizando os elementos B_4 e (c) B_8

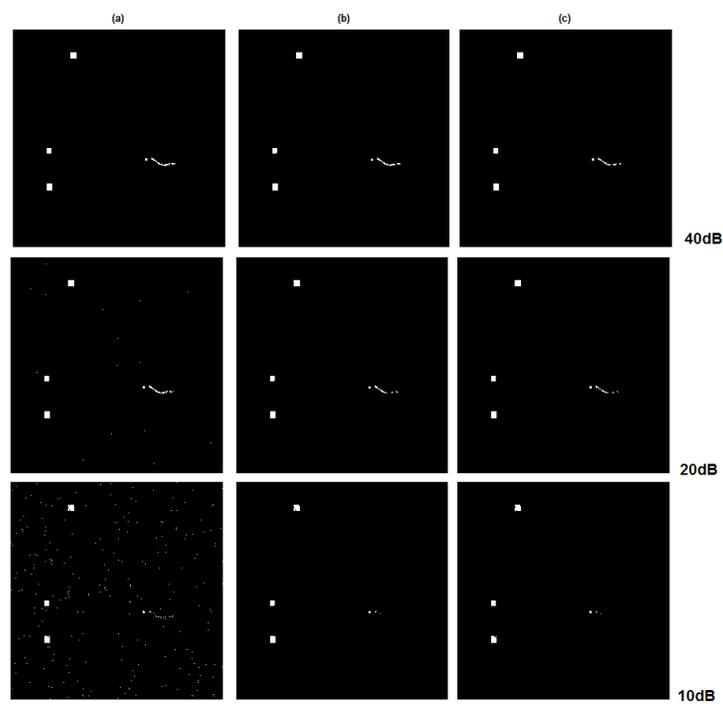


Figura 26 – Mapas de mudança resultantes da proposta rígida com $(1-\alpha)=99,74\%$: (a) sem filtragem, (b) com filtragem morfológica utilizando os elementos B_4 e (c) B_8

Visualmente, os resultados apresentados nas Figuras 25 e 26 são satisfatórios, contudo procedeu-se uma avaliação quantitativa. A Tabela 2 apresenta os indicadores quantitativos para avaliação do desempenho do classificador rígido em comparação ao mapa de referência, sem e com filtragem morfológica, sob diferentes níveis de ruído e com níveis de confiança variando de 90% a 99,74%.

Tabela 2 - Indicadores quantitativos de desempenho do classificador (sem e com filtragem morfológica) sob diferentes valores de SNR e com diferentes níveis de confiança (1- α).

$(1-\alpha)\times 100$	SNR (dB)	Sem filtragem morfológica				Filtragem com elemento B_4				Filtragem com elemento B_8			
		k	τ	FA	DR	k	τ	FA	DR	k	τ	FA	DR
90	10	0,049	0,902	0,971	0,890	0,869	0,999	0,057	0,806	0,874	0,999	0,000	0,777
90	20	0,155	0,967	0,913	0,970	0,974	1,000	0,004	0,953	0,958	1,000	0,000	0,919
90	30	0,991	1,000	0,003	0,984	0,987	1,000	0,001	0,974	0,982	1,000	0,000	0,966
90	40	0,993	1,000	0,000	0,986	0,989	1,000	0,001	0,978	0,984	1,000	0,000	0,969
95	10	0,094	0,949	0,947	0,866	0,872	0,999	0,007	0,778	0,859	0,999	0,000	0,754
95	20	0,329	0,987	0,799	0,962	0,966	1,000	0,003	0,938	0,944	1,000	0,000	0,894
95	30	0,989	1,000	0,000	0,979	0,983	1,000	0,001	0,967	0,975	1,000	0,000	0,952
95	40	0,992	1,000	0,000	0,983	0,987	1,000	0,001	0,976	0,979	1,000	0,000	0,959
99	10	0,308	0,988	0,807	0,810	0,844	0,999	0,001	0,731	0,843	0,999	0,000	0,730
99	20	0,800	0,998	0,305	0,944	0,944	1,000	0,001	0,895	0,924	1,000	0,000	0,858
99	30	0,984	1,000	0,000	0,969	0,973	1,000	0,001	0,947	0,954	1,000	0,000	0,912
99	40	0,985	1,000	0,000	0,971	0,976	1,000	0,001	0,954	0,962	1,000	0,000	0,926
99,74	10	0,564	0,996	0,553	0,771	0,830	0,999	0,000	0,710	0,826	0,999	0,000	0,704
99,74	20	0,930	1,000	0,071	0,931	0,928	1,000	0,000	0,866	0,915	0,999	0,000	0,843
99,74	30	0,981	1,000	0,000	0,963	0,968	1,000	0,001	0,939	0,945	1,000	0,000	0,896
99,74	40	0,982	1,000	0,000	0,965	0,970	1,000	0,001	0,943	0,947	1,000	0,000	0,900

Obs.: k = coeficiente kappa; τ = acurácia; FA=taxa de falsos alarmes; DR=taxa de detecção.

A Tabela 2 reforça os resultados apresentados nos mapas de mudança, revelando que os indicadores de desempenho sob altos níveis de ruído ($SNR \leq 20dB$) são insatisfatórios, se não for utilizado um procedimento de filtragem. Esse problema é acentuado, se associado com baixos níveis de confiança.

Devido à grande quantidade de informação, a avaliação visual da Tabela 3 pode ser uma tarefa bastante difícil para o analista. Com o objetivo de facilitar a interpretação dos resultados que a compõem, foram construídos dois conjuntos de gráficos. O primeiro conjunto é formado por curvas ROC onde os pontos representam as taxas FA e DR do classificador rígido sem e com filtragem morfológica para diferentes níveis de confiança (Figura 27). O segundo apresenta os valores do coeficiente de concordância kappa encontrados sob diferentes níveis de ruído, separadamente, para quatro níveis de confiança (Figura 28).

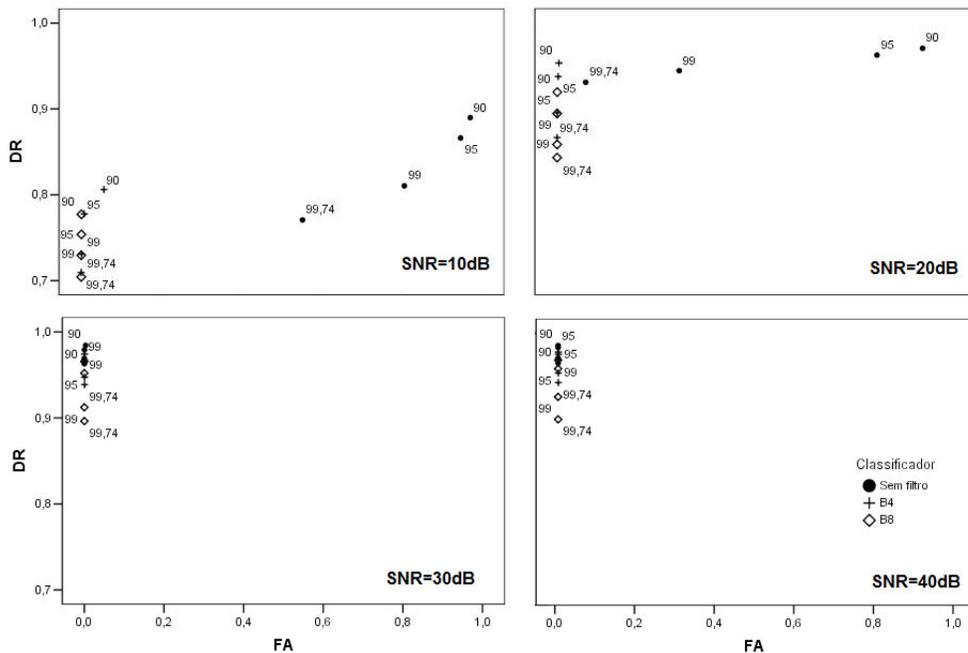


Figura 27 – Curvas ROC para diferentes valores de SNR (sem e com filtragem morfológica), e níveis de confiança (90, 95, 99 e 99,74%)

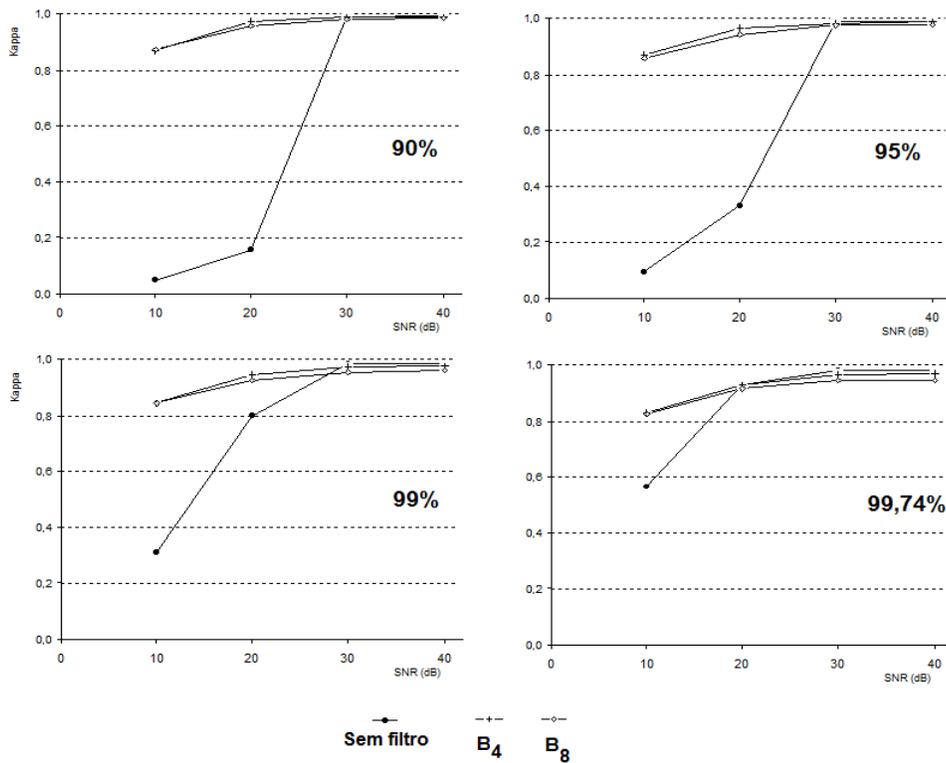


Figura 28 – Variação do coeficiente *kappa* em função do SNR (sem e com filtragem morfológica) para quatro diferentes níveis de confiança (90, 95, 99 e 99,74%)

Os resultados das Figuras 27 e 28 reforçam a necessidade de filtragem morfológica, pois, sem ela, os valores da taxa de FA aumentam demasiadamente sob a presença de ruído. Essa característica é ainda melhor percebida nas curvas de avaliação do coeficiente $kappa$, o qual, sem filtragem morfológica, atingiu valores inaceitáveis.

Os mapas de mudança binários (CM), produzidos pela classificação rígida, rotularam os pixels a uma das classes consideradas (ω_c ou ω_{nc}), mas não trouxeram informação sobre os tipos de mudança. A Figura 29 mostra um exemplo de mapa temático construído a partir da técnica de agrupamento K -médias, arbitrando-se $K=3$ e o diagrama de dispersão com a localização dos *clusters*. A imagem escolhida para geração do mapa temático ($1-\alpha=0,90$; filtro B_4) foi a combinação entre o nível de significância e o filtro que apresentou os melhores resultados nas curvas ROC para $SNR \leq 20$ dB. Outros mapas temáticos, associados às demais imagens binárias e com diferentes valores para K , poderiam ter sido construídos, entretanto julgou-se suficiente apresentar um a título de exemplificação.

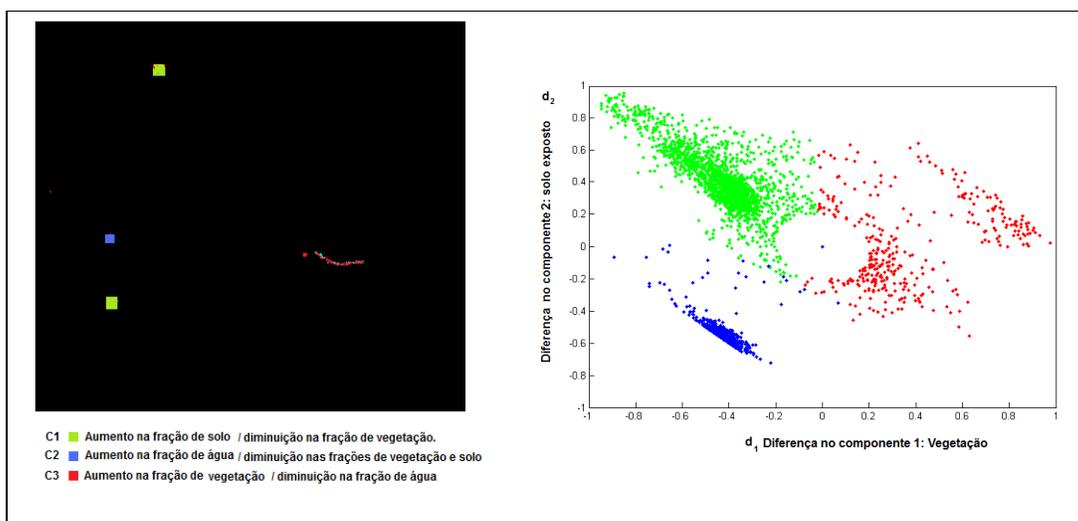


Figura 29 – Mapa temático construído a partir da análise de agrupamento para identificação dos tipos de mudança e gráfico de dispersão entre as diferenças de fração dos componentes vegetação e solo exposto – Experimento S1

Os três *clusters* identificados pelo algoritmo K -médias quase coincidem totalmente com as mudanças inseridas na imagem (Figura 24), refletindo as áreas de preparo para cultivo (C1), criação de um açude (C2) e aterro (C3). Os poucos pixels associados a um *cluster* diferente do previsto ocorreram principalmente na região de aterro, na parte rasa da Lagoa.

O experimento S1 seguiu com o procedimento de classificação suave. Aplicando a regressão logística, estimativas da probabilidade $P(\omega_c | \mathbf{d})$ para cada pixel foram produzidas,

flexibilizando a classificação. As estimativas para os parâmetros do modelo logístico foram obtidas a partir de uma amostra de 10% dos pixels da imagem para cada uma das 16 combinações: 4 níveis de confiança \times 4 níveis de ruído (Tabela 3).

Tabela 3 – Estimativas para o modelo de regressão logística utilizado na classificação suave para diferentes níveis de confiança e SNR

$(1-\alpha)\times 100$	SNR (dB)	$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$
90	10	-5,901	28,517	29,568
90	20	-6,571	33,983	21,858
90	30	-8,602	31,417	24,446
90	40	-13,720	22,862	23,801
95	10	-5,899	32,504	22,750
95	20	-6,365	27,211	23,901
95	30	-8,473	22,005	29,414
95	40	-14,194	25,517	22,728
99	10	-5,863	30,591	22,297
99	20	-6,804	25,555	31,497
99	30	-8,745	22,568	28,068
99	40	-14,644	24,201	24,013
99,74	10	-6,061	30,426	26,546
99,74	20	-6,348	29,034	21,886
99,74	30	-9,087	19,118	27,630
99,74	40	-14,113	25,190	20,904

Apesar de os parâmetros da regressão logística variarem em função da presença de ruído na imagem, eles mostraram-se pouco influenciados pelo nível de significância adotado. Neste experimento, em que $v=2$, a Equação 27 foi utilizada para determinar a probabilidade de um pixel pertencer à classe de mudança:

$$\hat{P}(\omega_c | \mathbf{d}) = \frac{\exp\{\hat{\beta}_0 + \hat{\beta}_1 d_1 + \hat{\beta}_2 d_2\}}{1 + \exp\{\hat{\beta}_0 + \hat{\beta}_1 d_1 + \hat{\beta}_2 d_2\}} \quad (27)$$

Assim, por exemplo, um pixel $\mathbf{d}=[-0,2;0,2]$ da imagem de diferenças, na combinação de um nível de confiança 95% e SNR=20, terá sua probabilidade de pertencer à classe ω_c estimada pela Equação 28:

$$\hat{P}(\omega_c | |\mathbf{d}|) = \frac{\exp\{-6,365 + 27,211 \times |-0,2| + 23,901 \times 0,2\}}{1 + \exp\{-6,365 + 27,211 \times |-0,2| + 23,901 \times 0,2\}} = 0,9793 \quad (28)$$

A Figura 30 apresenta os mapas de probabilidade resultados, considerando três diferentes níveis de confiança.

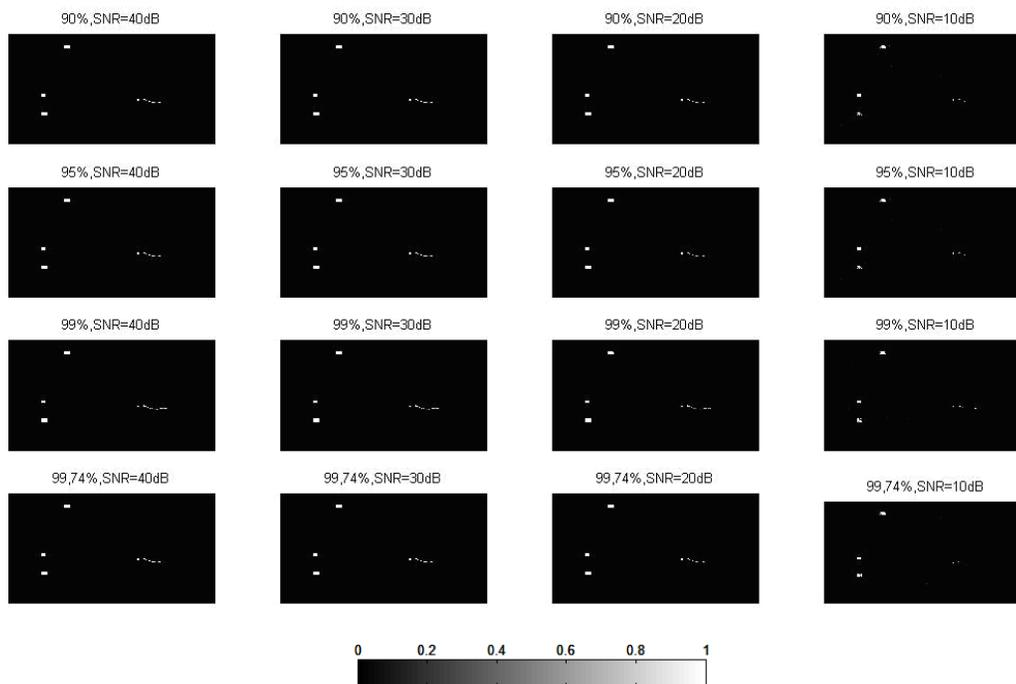


Figura 30 – Mapas da probabilidade de pertencer à classe ω_c para diferentes níveis de confiança e valores de SNR

Os mapas de probabilidade, à primeira vista, parecem apresentar apenas valores extremos (0 e 1), entretanto níveis intermediários também ocorrem. O histograma na Figura 31 mostra um exemplo em que, de fato, os extremos concentram a maior parte dos pixels, entretanto valores intermediários também ocorrem.

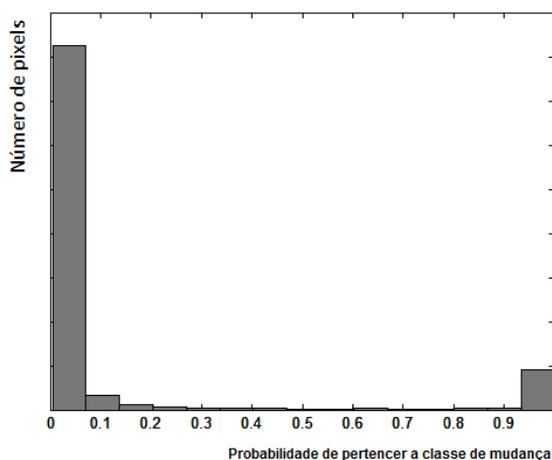


Figura 31 – Histograma da probabilidade de pertencer à classe ω_c para $(1-\alpha)=95\%$ e SNR=20dB

A regressão logística permitiu estimar a probabilidade de pertencer à classe ω_c para cada pixel. Isso significa que a probabilidade de o pixel “por inteiro” pertencer à classe de mudança foi estimada. No entanto é provável que mudanças ocorram em nível de subpixel, especialmente em se tratando de imagens como a Landsat-TM, cujo pixel corresponde a uma área de 900m^2 no terreno. A abordagem *fuzzy*, proposta na seção 3.5.1, permitiu gerar mapas de mudança CM_{fuzzy} compostos pelos graus de pertinência à classe ω_c (Figura 32). Salienta-se que não houve necessidade de intervenção alguma por parte do analista; o único dado de entrada foram as imagens de fração em t_1 e t_2 .

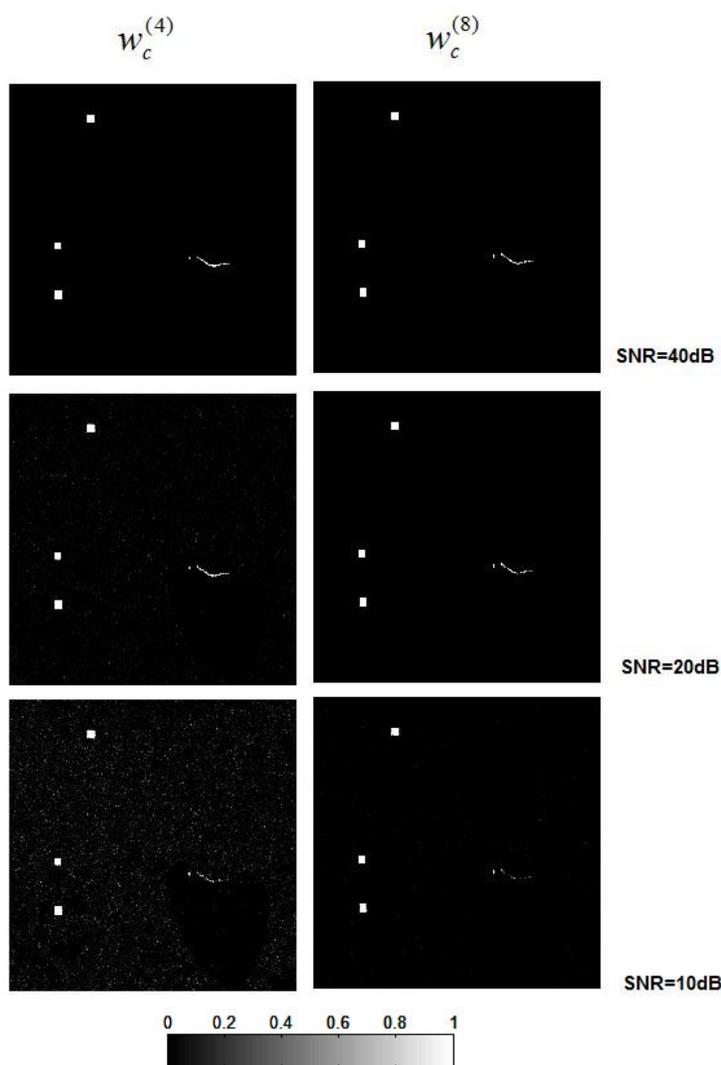


Figura 32 – Mapas dos graus de pertinência à classe ω_c utilizando dois esquemas de vizinhança e sob diferentes valores de SNR

Os resultados da proposta *fuzzy* praticamente reproduziram os mapas de mudança binários produzidos na classificação rígida, sob baixos níveis de ruído, visto que os graus de pertinência se concentraram nos extremos (0 e 1). Sob baixo valor de SNR, os graus de pertinência $w_c^{(4)}$ foram contaminados pelo ruído, efeito que foi minimizado no esquema com oito vizinhos ($w_c^{(8)}$). A Figura 33 apresenta os histogramas para SNR=10 e 20dB.

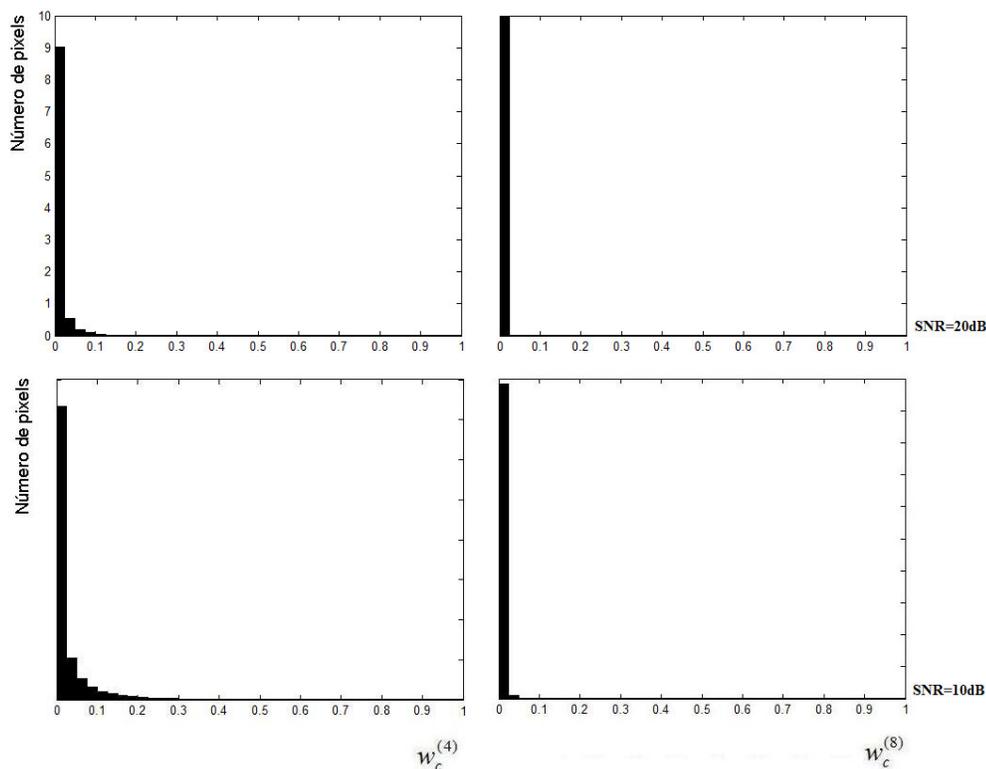


Figura 33 – Histograma dos graus de pertinência dos mapas CM_{fuzzy} utilizando dois esquemas de vizinhança – Experimento S1 com SNR=10 e 20dB.

Embora a imagem dos graus de pertinência $w_c^{(4)}$ para SNR=10dB possa sugerir que os resultados não foram satisfatórios, o histograma revela que os mesmos se concentram abaixo de 0,30, o que indica mudanças de magnitude baixa nesses pixels. Esse resultado é esperado em imagens com alto nível de ruído, uma vez que na proposta *fuzzy* se detecta o nível de mudança interna no pixel e, nessas situações, é natural que o ruído seja responsável por uma parcela importante das alterações. No caso $w_c^{(8)}$ e SNR=20dB, a proposta *fuzzy* praticamente se iguala à rígida.

4.1.2 Experimento S2

O experimento S2 consiste de um recorte de 1000×1000 pixels da cena correspondente à órbita 220, ponto 21, do sistema sensor Landsat-TM (Figura 34). De um total de sete bandas espectrais disponibilizadas, seis foram utilizadas, ficando ausente apenas a banda correspondente à faixa termal, devido à menor resolução espacial.

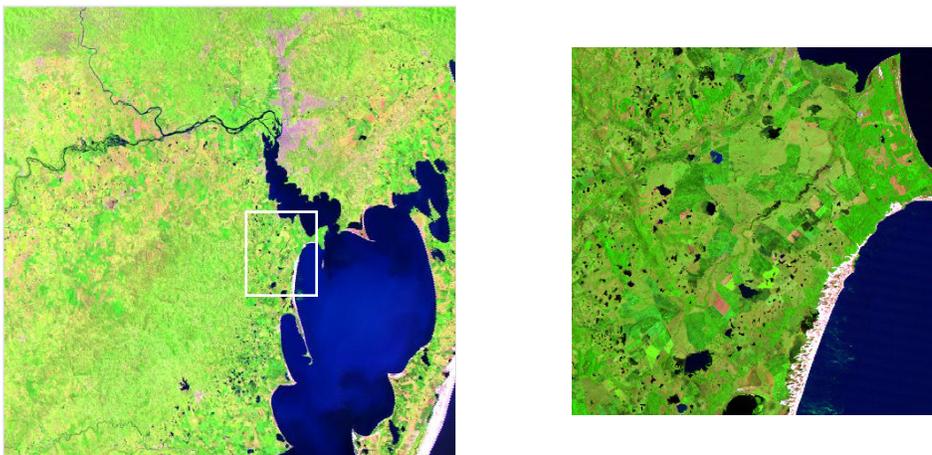


Figura 34 – Cena Landsat-TM correspondente à órbita-ponto 220/81 e detalhe do recorte efetivamente utilizado no experimento S2

A área do recorte abrange principalmente os municípios de Barra do Ribeiro e Tapes, Rio Grande do Sul. A região caracteriza-se pela presença de três unidades geomorfológicas segundo o IBGE (2003): Planície Lagunar, Planície Litorânea Interna, Planície Alúvio-Coluvionar. Para geração das imagens de fração, três *endmembers* foram considerados – vegetação, solo exposto e água – conforme apresentado na Figura 35.

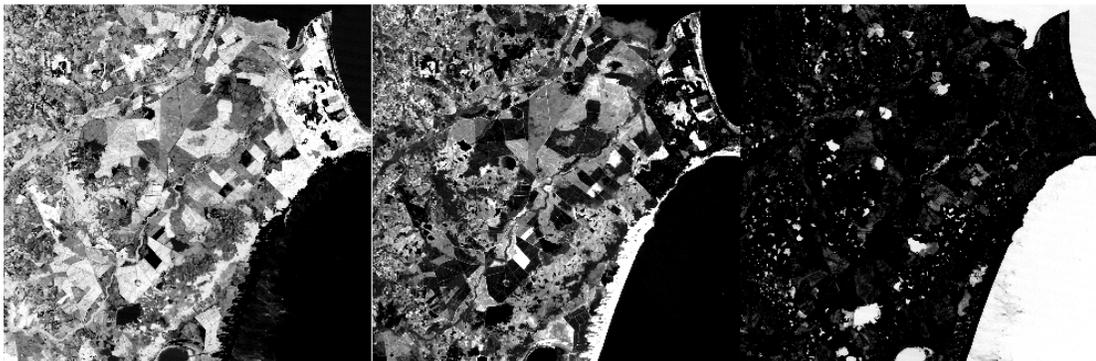


Figura 35 – Imagens de fração utilizadas no experimento S2: vegetação, solo exposto e água

As imagens de diferença foram criadas pela operação de subtração entre as imagens ruidosas adicionadas das regiões de mudança e a imagem original. A Figura 36 apresenta uma imagem de diferença contaminada por ruído gaussiano e o mapa de referência.

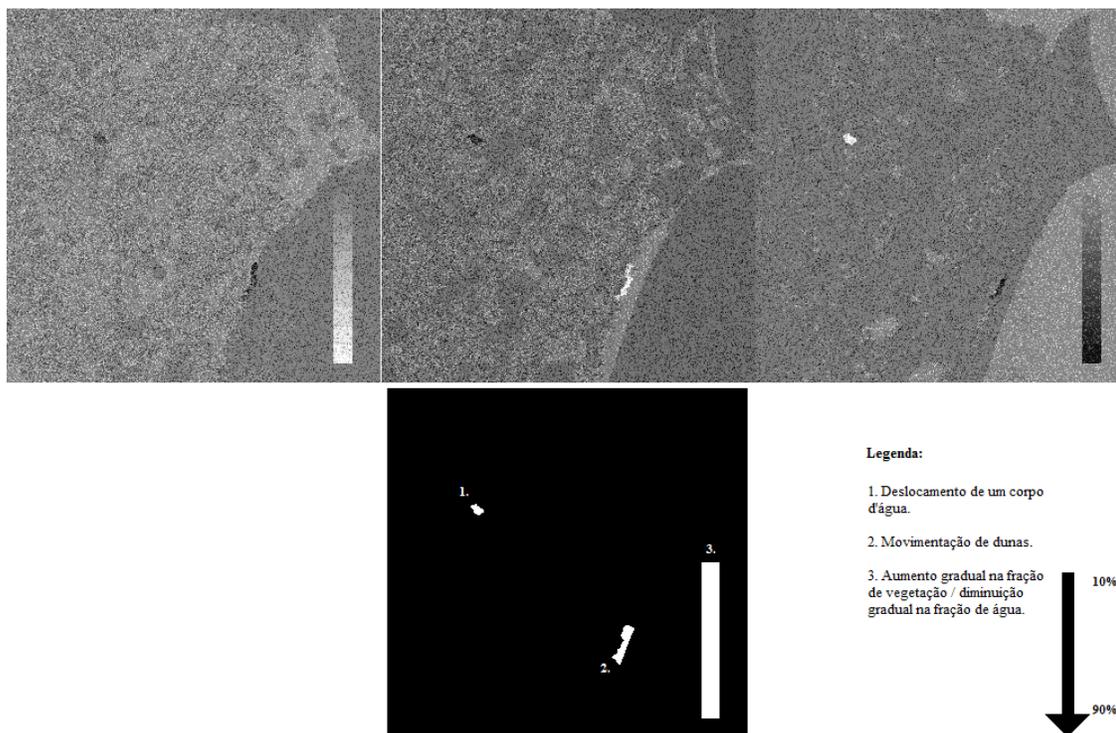


Figura 36 – Imagens de diferenças de fração contaminada com ruído (SNR=10dB) e mapa de referência – Experimento S2

Este experimento contém duas regiões não retangulares de alteração e uma barra que simula uma mudança gradual nas frações de água e vegetação. A diminuição na fração de água variou de 10% até 90%, sendo o valor subtraído adicionado à fração de vegetação. Essas modificações em áreas não retangulares foram inseridas para melhor avaliação dos operadores morfológicos. A barra de mudanças gradual objetiva uma melhor avaliação dos procedimentos de classificação *suave* e *fuzzy*.

Assim como no experimento S1, os resultados para altos valores de SNR foram excelentes em S2. Por esse motivo, optou-se por analisar apenas imagens bastante ruidosas ($SNR \leq 15dB$). A Figura 37 apresenta os mapas de mudanças de binários construídos a partir da proposta rígida para SNR=10dB para $(1-\alpha)=90\%$.

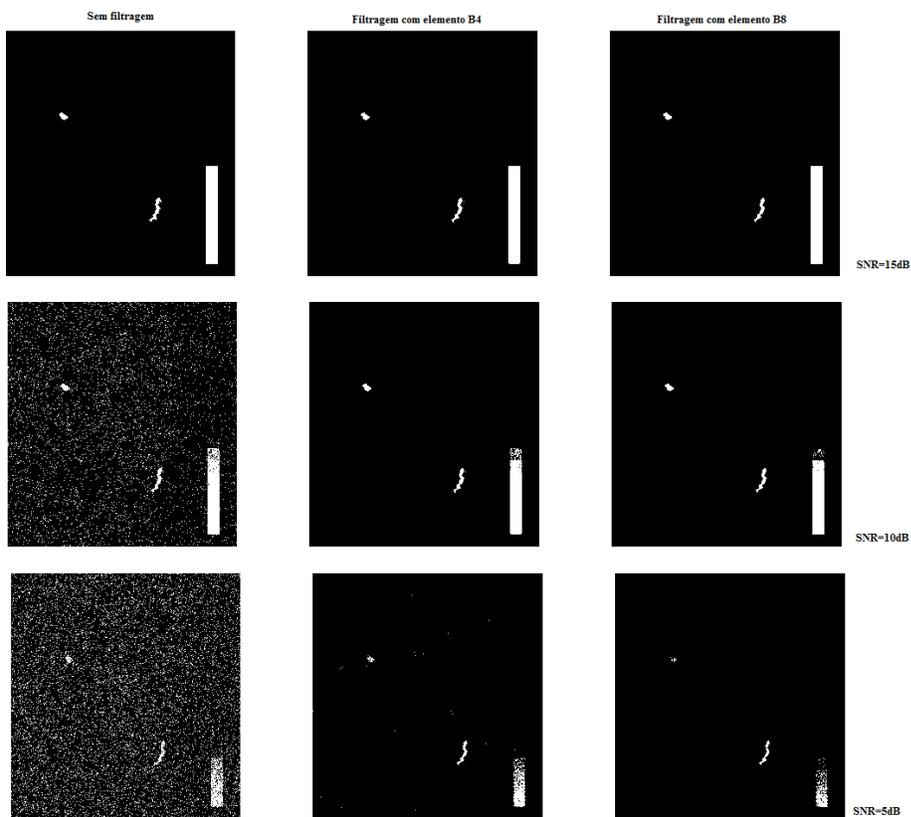


Figura 37 – Mapas de mudança binários resultantes da proposta rígida com $(1-\alpha)=90\%$: sem filtragem e com filtragem morfológica utilizando os elementos B_4 e B_8

A Tabela 4 sintetiza os resultados da avaliação quantitativa do classificador rígido, considerando quatro diferentes níveis de confiança.

Tabela 4 - Indicadores quantitativos de desempenho do classificador (sem e com filtragem morfológica) sob diferentes valores de SNR e com diferentes níveis de confiança $(1-\alpha)$.

$(1-\alpha) \times 100$	SNR (dB)	Sem filtragem morfológica				Filtragem com elemento B_4				Filtragem com elemento B_8			
		k	τ	FA	DR	k	τ	FA	DR	k	τ	FA	DR
90	5	0,105	0,874	0,914	0,409	0,484	0,983	0,020	0,327	0,349	0,980	0,000	0,216
90	10	0,349	0,936	0,750	0,739	0,828	0,993	0,002	0,713	0,806	0,992	0,000	0,681
90	15	0,927	0,997	0,000	0,867	0,925	0,997	0,000	0,864	0,924	0,996	0,000	0,862
95	5	0,158	0,933	0,864	0,302	0,351	0,980	0,002	0,217	0,199	0,977	0,000	0,113
95	10	0,520	0,970	0,555	0,669	0,789	0,991	0,001	0,657	0,775	0,991	0,000	0,639
95	15	0,867	0,994	0,000	0,770	0,865	0,994	0,000	0,766	0,864	0,994	0,000	0,765
99	5	0,199	0,965	0,741	0,185	0,166	0,977	0,000	0,093	0,064	0,975	0,000	0,034
99	10	0,679	0,985	0,243	0,627	0,746	0,990	0,000	0,601	0,724	0,989	0,000	0,574
99	15	0,867	0,994	0,000	0,769	0,864	0,994	0,000	0,766	0,864	0,994	0,000	0,765
99,74	5	0,107	0,972	0,706	0,072	0,033	0,975	0,000	0,017	0,011	0,974	0,000	0,005
99,74	10	0,685	0,987	0,087	0,555	0,702	0,988	0,000	0,548	0,681	0,988	0,000	0,523
99,74	15	0,852	0,993	0,000	0,747	0,845	0,993	0,000	0,737	0,829	0,993	0,000	0,713

Obs.: k = coeficiente kappa; τ = acurácia; FA=taxa de falsos alarmes; DR=taxa de detecção.

Os resultados da Tabela 5 e da Figura 37 mostram que, à medida que aumenta o nível de ruído, aumenta a taxa de FA e diminui a DR. A filtragem morfológica pode praticamente eliminar os falsos alarmes, entretanto ela diminuiu a taxa de detecção. Percebeu-se, também que, nas imagens com muito ruído, as mudanças graduais com percentuais inferiores a 60% (ver Figura 36) tenderam a desaparecer.

A filtragem morfológica com alto nível de ruído (SNR=5dB) também reduziu demasiadamente as áreas correspondentes às regiões de mudança não-retangulares. Por outro lado, quando $SNR \geq 10dB$, ambos os elementos estruturantes preservaram satisfatoriamente as formas originalmente inseridas.

As curvas ROC, apresentadas na Figura 38, mostram que o classificador rígido sem filtragem teve bom desempenho apenas quando $SNR=15dB$. Nas imagens mais ruidosas, os resultados sem filtragem são insatisfatórios. O elemento estruturante B_4 combinado como nível de confiança de 90% produziu os melhores resultados, tanto para 10 como para 5dB.

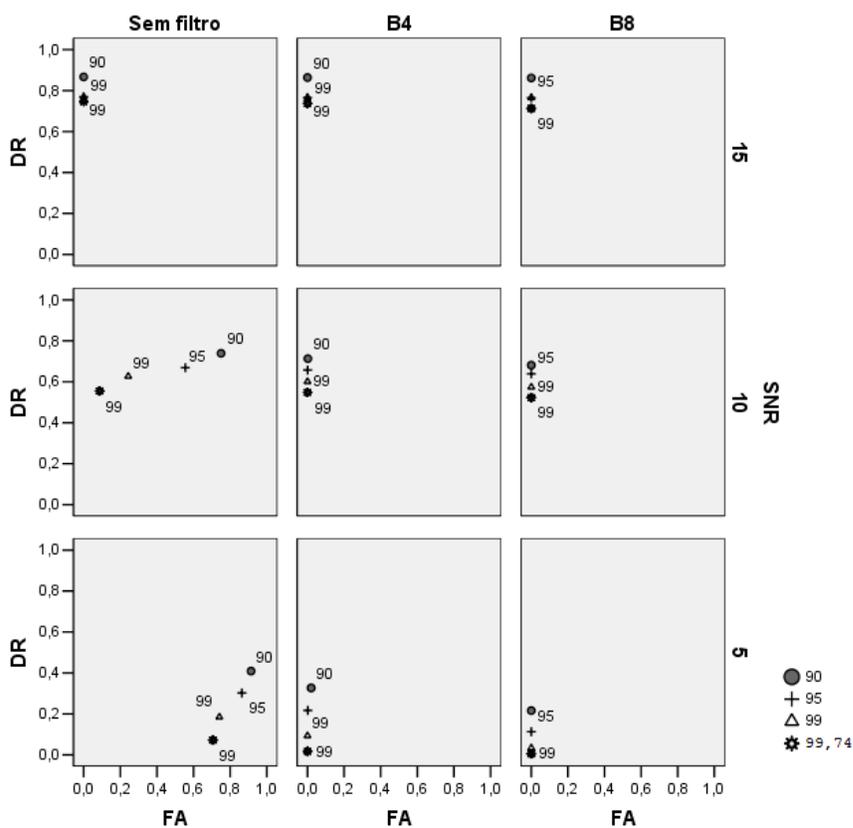


Figura 38 – Curvas ROC para diferentes valores de SNR (sem e com filtragem morfológica), e níveis de confiança (90, 95, 99 e 99,74%) – Experimento S2

Para identificação dos tipos de alteração foi realizada uma análise de agrupamento com $K=4$ sobre a imagem de diferenças combinada com o mapa **CM'** gerado pelo operador **B₄** para o nível de confiança de 90%. O mapa temático resultante é apresentado na Figura 38, sendo os centróides dos *clusters*:

- Cluster 1*: [-0,4433; +0,7567; -0,3368];
Cluster 2: [+0,4065; -0,0374; -0,4056];
Cluster 3: [+0,7380; -0,0368; -0,7396];
Cluster 4: [-0,3985; -0,5004; +0,8476].

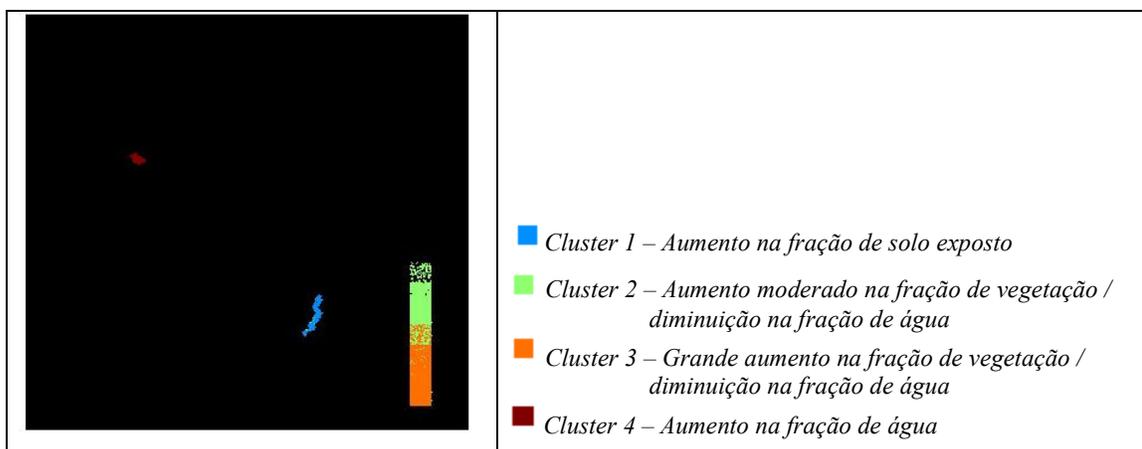


Figura 39 – Mapa temático construído a partir da análise de agrupamento – Experimento S2

O *Cluster 1* se refere à movimentação da duna como um aumento na fração de solo exposto. Os *Clusters 2* e *3* indicam a região com aumento de vegetação e diminuição da fração de água. O *Cluster 4* identificou corretamente a duplicação de um corpo d'água, a qual ocasionou aumento na fração de água associada à diminuição da vegetação e solo exposto.

A classificação rígida não pode representar a região de mudanças com diferentes graus de alteração. Procedeu-se, então, a classificação suave via modelo de regressão logística, a qual tem a capacidade de representar valores intermediários entre 0 e 1. Os parâmetros estimados para os três diferentes valores de SNR e quatro níveis de confiança são apresentados na Tabela 5.

Tabela 5 – Estimativas para o modelo de regressão logística utilizado na classificação suave para diferentes níveis de confiança e SNR – Experimento S2

$(1-\alpha)\times 100$	SNR (dB)	$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$
90	5	- 12,211	11,234	4,132
90	10	- 13,980	34,085	12,040
90	15	- 8,644	35,699	7,614
95	5	- 10,769	11,131	3,220
95	10	- 13,832	37,109	11,295
95	15	- 8,884	36,409	8,976
99	5	- 9,481	10,436	1,844
99	10	- 12,503	34,868	8,905
99	15	- 6,572	42,003	8,937
99,74	5	- 15,661	4,812	12,341
99,74	10	- 14,577	32,189	14,589
99,74	15	- 9,792	35,687	9,421

As estimativas para os parâmetros da regressão logística novamente variaram bastante, indicando que a combinação entre o nível de confiança e o valor de SNR pode gerar mapas das probabilidades de mudança um tanto distintos. Os mapas de probabilidades para $(1-\alpha)=90\%$ com SNR= 5, 10 e 15dB são apresentados na Figura 40.

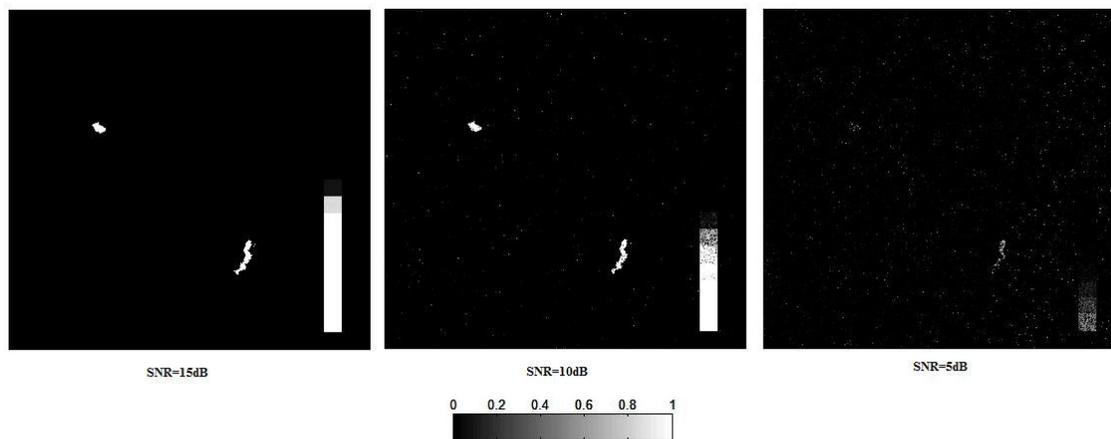


Figura 40 – Mapas da probabilidade de pertencer à classe ω_c para diferentes nível de confiança de 90% e valores de SNR \leq 15dB

O mapa de probabilidades para SNR=15dB apresentou resultado similar ao classificador rígido, no entanto é possível perceber áreas com probabilidades inferiores a 1 no caso de pequenas mudanças. Para SNR=10dB parte das alterações graduais foi detectada, levando a um resultado muito superior ao encontrado com o classificador rígido. Quando SNR baixou para 5dB, apenas as mudanças muito fortes foram detectadas.

Finalizando o experimento S2, mapas dos graus de pertinência à classe ω_c foram construídos considerando os dois esquemas de vizinhança propostos (Figura 41).

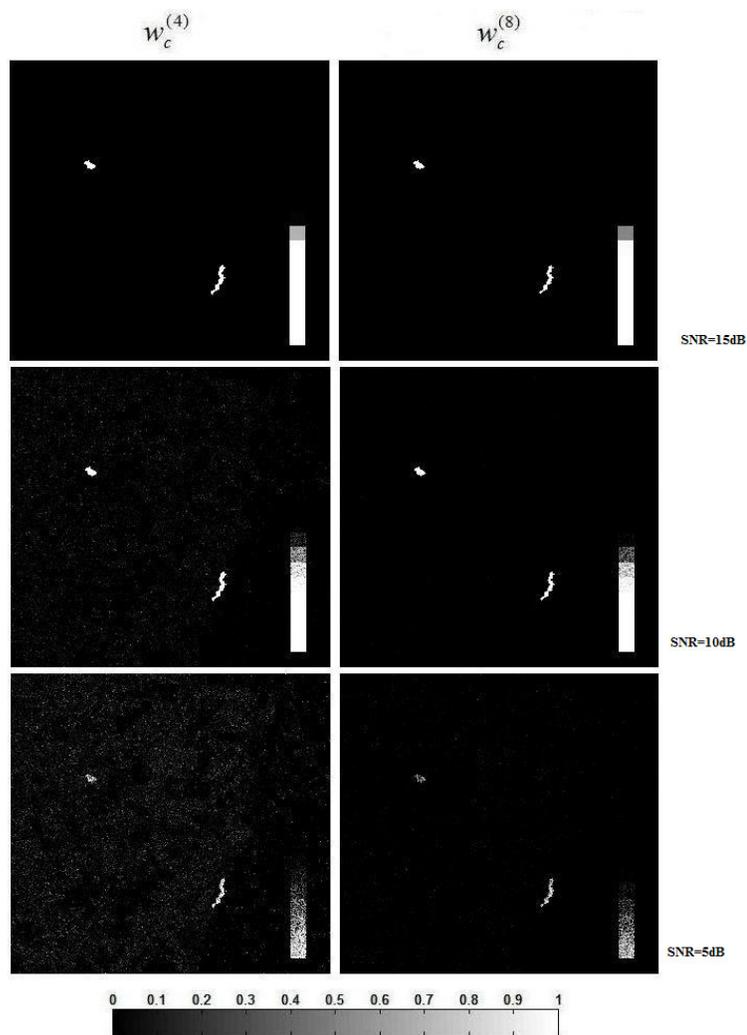


Figura 41 – Mapas dos graus de pertinência à classe ω_c utilizando dois esquemas de vizinhança e sob diferentes valores de SNR

Os mapas dos graus de pertinência revelam que a proposta alicerçada na teoria *fuzzy* é capaz de representar os níveis graduais de mudança inseridos na imagem, entretanto os mapas não reproduziram todos os nove diferentes níveis de mudança. Para a imagem menos ruidosa, o mapa *fuzzy* resultou quase binário, como na proposta rígida. Para SNR=10 e 5dB, há melhor representação dos níveis graduais de mudança, mas há perda de informação, uma vez que áreas com pequeno nível de alteração foram associadas a graus de pertinência nulos.

4.2 EXPERIMENTOS COM IMAGENS LANDSAT-TM

4.2.1 Experimento R1

O experimento R1 consiste de um recorte de 1000×1000 pixels da cena correspondente à órbita 221, ponto 81, do sistema sensor Landsat-TM. A região caracteriza-se por apresentar uma extensa faixa de planície fluvial que abrange os municípios de Capela de Santana, Portão, Eldorado do Sul, Charqueadas, Triunfo, Nova Santa Rita e Montenegro, estado do Rio Grande do Sul. Os dois rios presentes no recorte são o Jacuí e Caí.

A imagem em t_1 é de 01/Out/2007, data que corresponde a um período de cheia no qual houve transbordamento dos rios Caí e Jacuí devido aos altos índices de precipitação registrados. A imagem em t_2 é de 06/Fev/2008, data que não se aproxima de nenhum evento natural extremo. A Figura 42 apresenta as cenas completas e os recortes utilizados neste experimento.

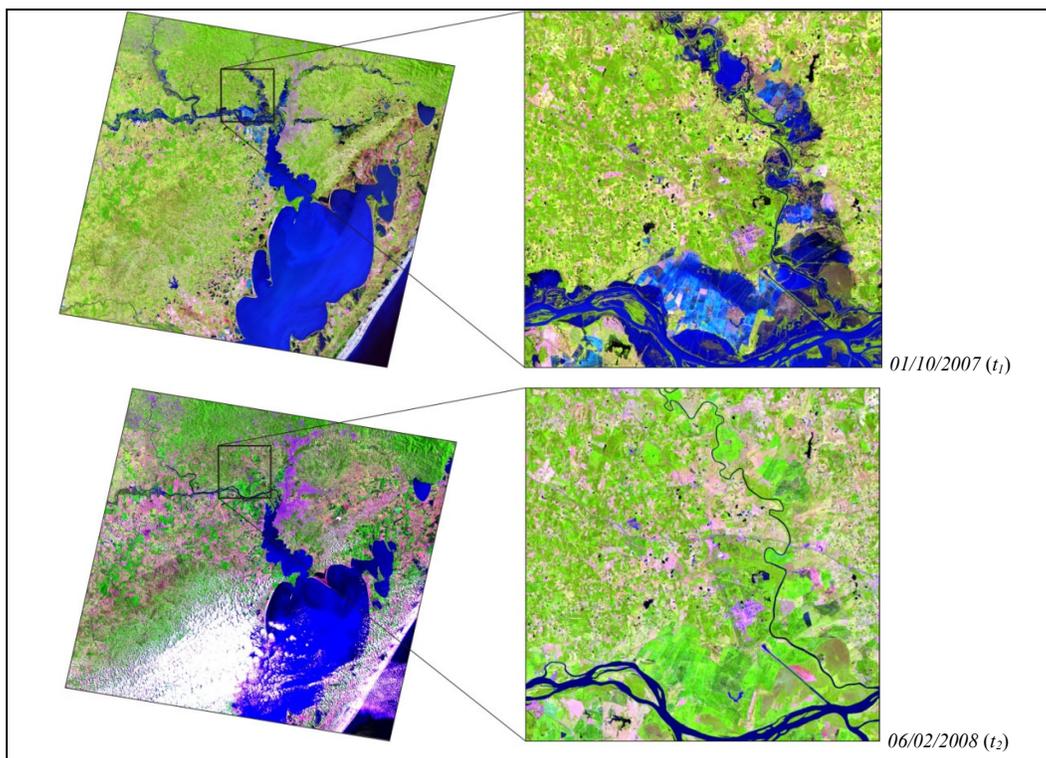


Figura 42 – Cenas Landsat-TM correspondentes à órbita-ponto 220/81 e detalhes dos recortes efetivamente utilizados no experimento R1

As seis bandas espectrais do sensor TM com resolução espacial de 30m foram utilizadas na geração das imagens de fração. A escolha dos *endmembers* levou em

consideração a assinatura espectral dos pixels “puros” nas duas imagens e também as suas localizações, de forma que os pixels correspondentes a um mesmo *endmember* fossem próximos nas duas imagens. Foram considerados três membros finais: vegetação, solo exposto e água. As imagens de fração em t_1 e t_2 são apresentadas na Figura 43.

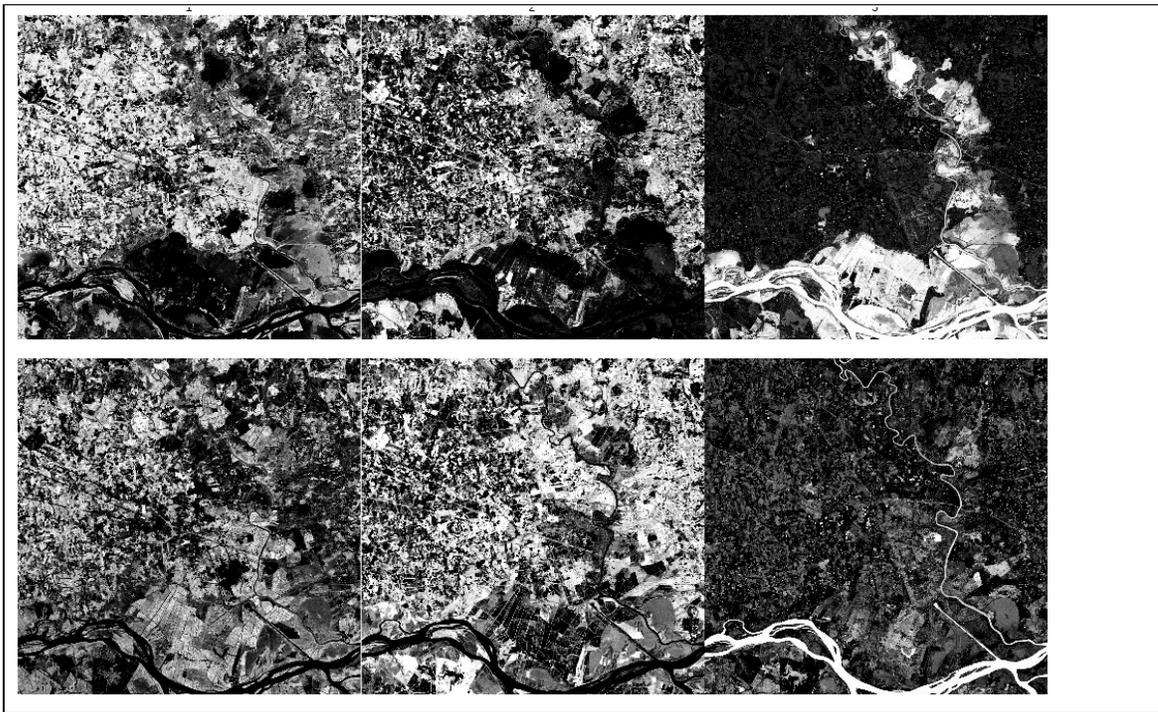


Figura 43 – Imagens de fração considerando três *endmembers* – vegetação, solo exposto e água – para as duas imagens do experimento R1. Acima o recorte da cena em t_1 e abaixo em t_2 .

Nesse experimento, assim como nos demais realizados sobre pares de imagens reais, os resultados não foram submetidos a uma análise quantitativa. Os resultados gerados pelo classificador rígido para quatro diferentes níveis de confiança são apresentados na Figura 44. A análise visual dos mapas de mudança indica que, neste experimento, os níveis de confiança de 90% e 95% associados aos filtros morfológicos produziram os melhores resultados, pois detectaram satisfatoriamente a área inundada ao longo do curso dos rios Jacuí e Caí. Os níveis de confiança mais elevados (99 e 99,74%) deixaram de detectar importantes áreas de mudança que podem ser identificadas facilmente por meio de análise visual das imagens originais.

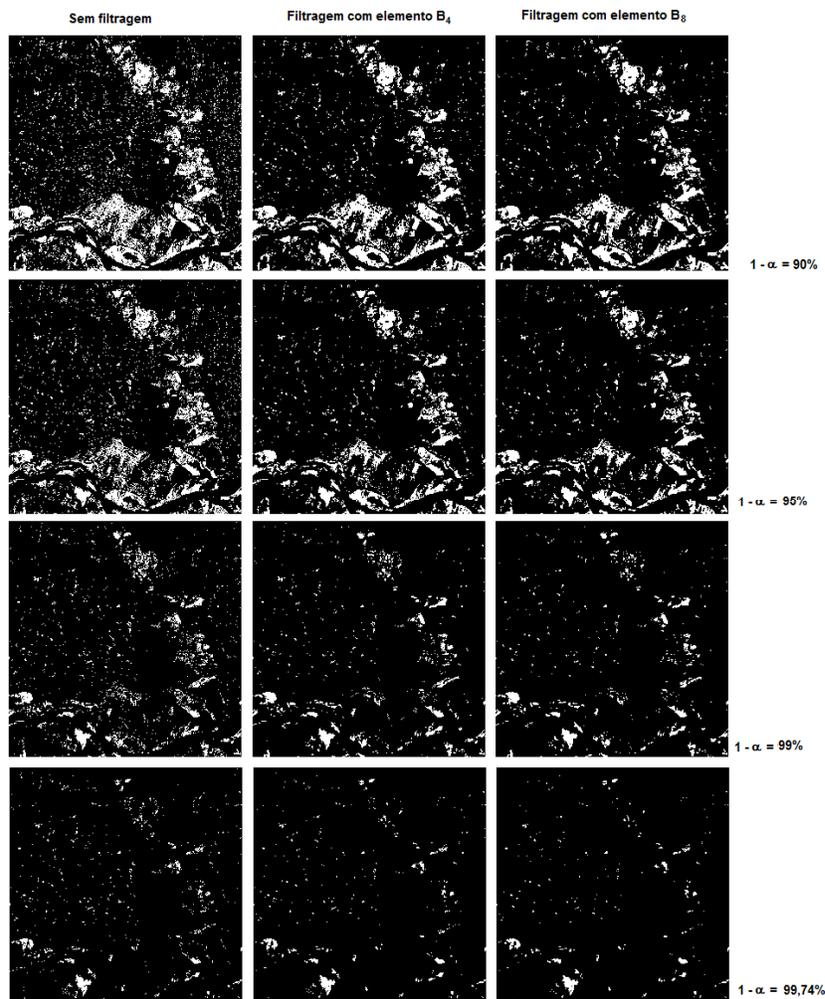


Figura 44 – Mapas de mudança resultantes da proposta rígida no experimento R1 com quatro diferentes níveis de confiança, (a) sem filtragem, (b) com filtragem morfológica utilizando o elemento B_4 e (c) com filtragem morfológica utilizando o elemento B_8 .

A Figura 45 apresenta os diagramas de dispersão entre as três frações, sendo que a elipse vazia na região central indica os pixels classificados na classe ω_{nc} . A análise de agrupamento foi realizada a partir do produto entre o mapa binário (CM') com $1-\alpha=90\%$ e o filtro morfológico B_8 para $K=3$. Os três *clusters* identificados apresentam os seguintes vetores de média (centróides):

Cluster 1: $[+0,0872; +0,7277; -0,8149]$;

Cluster 2: $[+0,6056; +0,0565; -0,6621]$;

Cluster 3: $[-0,5020; +0,7637; -0,1616]$.

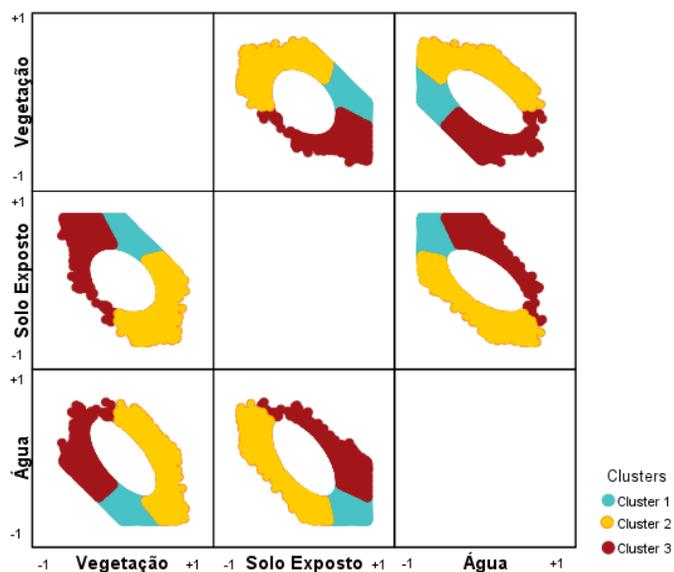


Figura 45 – Gráfico de dispersão entre as diferenças de fração – componentes vegetação, solo exposto e água – Experimento R1

O mapa temático resultante da análise de agrupamento é apresentado na Figura 46, o qual preserva o mesmo esquema de cores da Figura 45. A interpretação dos *clusters* fica facilitada ao lembrar que a imagem de diferenças foi realizada pela operação $D=F_2-F_1$, em que t_1 corresponde à data na qual houve o evento de transbordamento.

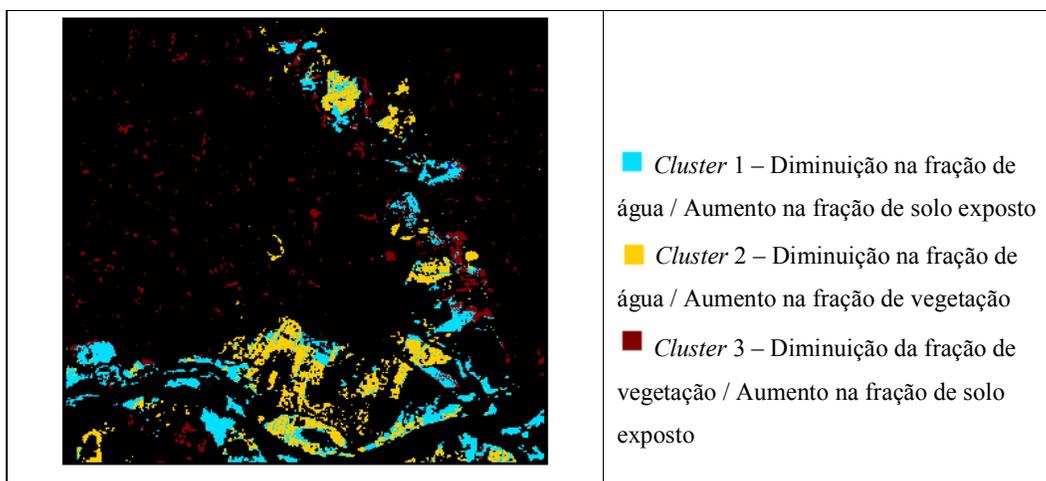


Figura 46 - Mapa temático construído a partir da análise de agrupamento para identificação dos tipos de mudança – Experimento R1

O *Cluster 1* é associado às áreas que estavam inundadas em t_1 e que, depois, no período de vazante (t_2), revelaram solo exposto. O *Cluster 2* também se refere às áreas que estavam inundadas em t_1 , mas que, em t_2 , revelaram aumento na fração de vegetação (áreas cultivadas). O *Cluster 3* apresenta áreas com diminuição na fração de vegetação e aumento na fração de solo exposto. Isso é decorrência da dinâmica do uso do solo (preparo para cultivo e colheita) e também do fato de ser verão em t_2 e primavera em t_1 .

Assim como nos experimentos com dados sintéticos, buscou-se flexibilizar os resultados da classificação rígida. A Tabela 6 apresenta as estimativas para o modelo de regressão logística com diferentes níveis de confiança.

Tabela 6 – Estimativas para o modelo de regressão logística utilizado no experimento R1 para classificação suave com diferentes níveis de confiança

$(1-\alpha)\times 100$	$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$
90	-8,696	0,779	10,463
91	-7,294	3,609	8,286
92	-7,034	5,027	7,767
93	-6,998	5,973	7,670
94	-6,963	6,635	7,566
95	-6,928	6,861	7,665
96	-6,866	7,196	7,603
97	-6,834	7,556	7,533
98	-6,677	7,433	7,481
99	-6,725	7,793	7,531
99,74	-22,220	-0,697	24,446

Ao contrário do experimento S1, os parâmetros do modelo de regressão logística mostraram maior variabilidade de acordo com o nível de confiança escolhido. Entre 93 e 99%, houve certa estabilidade dos parâmetros, no entanto, para os extremos da tabela, as estimativas foram muito distintas. Esse resultado pode ser creditado ao fato de que a escolha do nível de significância faz uma seleção das classes presentes na imagem. Utilizando-se 99,74%, por exemplo, a única classe de mudança presente foi aquela correspondente ao *cluster 1*, pois a informação disponível para estimação dos parâmetros não era a mesma. Os mapas de probabilidade (CMP) para quatro níveis de confiança, construídos a partir das estimativas da Tabela 5, são apresentados na Figura 47.

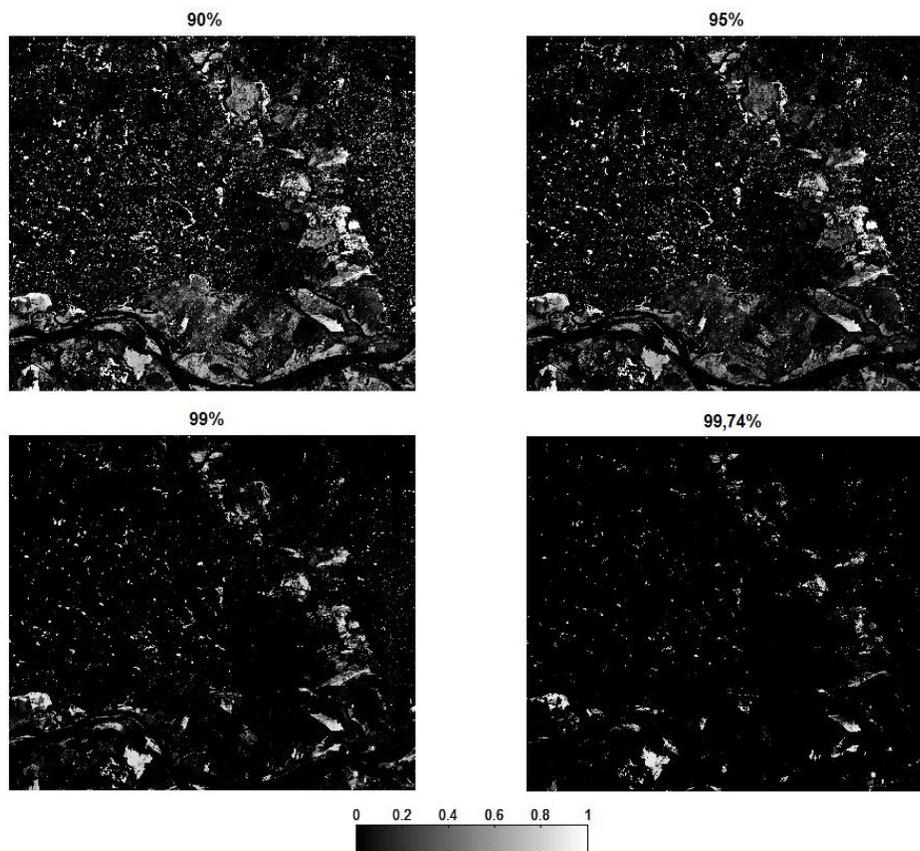


Figura 47 – Mapas da probabilidade de pertencer à classe ω_c para diferentes níveis de confiança

Um exemplo da superfície utilizada para estimação das probabilidades de pertencer à classe de mudanças em função do módulo das diferenças de fração é apresentado na Figura 48.

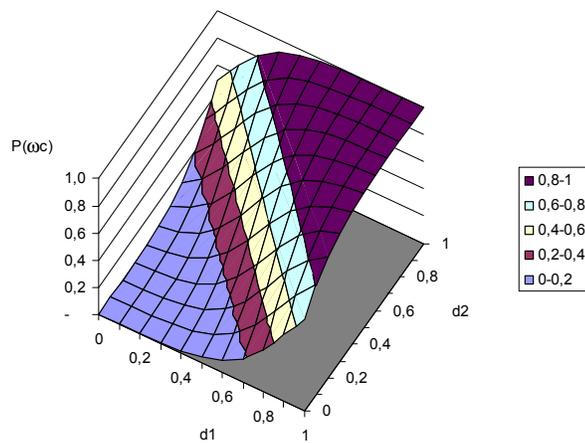


Figura 48 – Superfície estimada por regressão logística utilizada para estimação das probabilidades de pertencer à classe de mudanças $(1-\alpha)=95\%$.

Por fim, o mapa de mudanças *fuzzy* (CM_{fuzzy}) foi gerado com os dois esquemas de vizinhança propostos. Os resultados, apresentados na Figura 49, são semelhantes aos mapas de probabilidade com níveis de confiança de 90% e 95%, entretanto os mapas *fuzzy* parecem ter preservado mais informações referentes às mudanças ocorridas de t_1 para t_2 , além de minimizarem a presença de ruído.

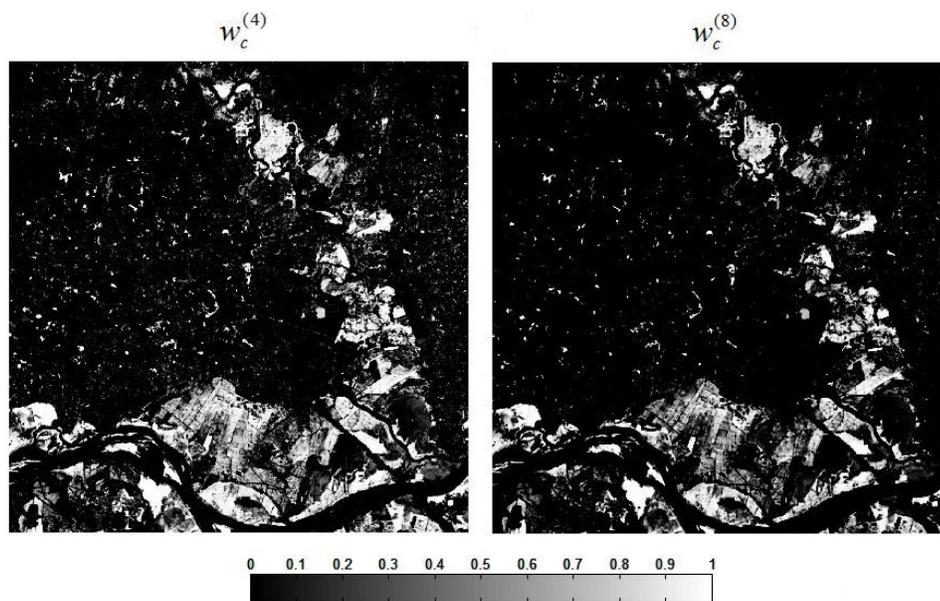


Figura 49 – Mapas dos graus de pertinência à classe ω_c utilizando dois esquemas de vizinhança

Os histogramas apresentados na Figura 50 mostram que, embora haja uma concentração de graus de pertinência nos extremos, valores intermediários também são abundantes, o que não deixa de ser desejável e esperado em mapas construídos seguindo uma lógica *fuzzy*.

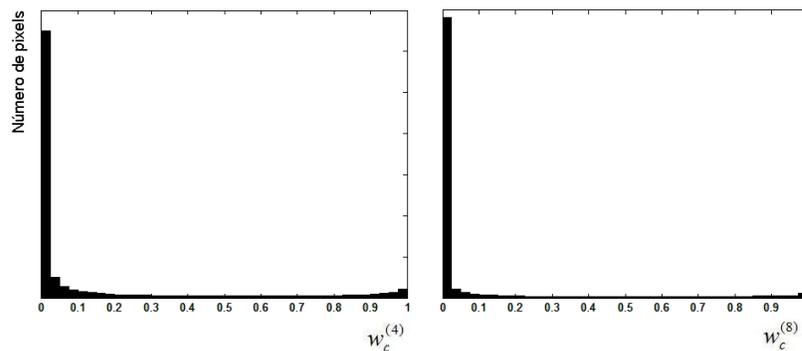


Figura 50 – Histograma dos graus de pertinência dos mapas CM_{fuzzy} utilizando dois esquemas de vizinhança

4.2.2 Experimento R2

O experimento R2 consiste de um recorte de 625×625 pixels da cena correspondente à órbita 233, ponto 57, do sistema sensor Landsat-TM. As duas imagens utilizadas datam de novembro de 1994 (t_1) e janeiro de 1996 (t_2) e correspondem a uma área de aproximadamente 350 km^2 localizada ao norte do Brasil, próxima da fronteira com a Venezuela e a Guayana (Figura 51).



Figura 51 – Localização da área de estudo

Fonte: Haertel, Shimabukuro e Almeida-Filho, 2004.

A área de estudo compreende duas regiões bem distintas que podem ser facilmente identificadas na Figura 52. A primeira área consiste de uma região de baixa elevação coberta pela floresta amazônica, enquanto a segunda se localiza numa região mais elevada conhecida como Platô Tepequem. Uma descrição mais detalhada da região de estudo pode ser encontrada em Haertel et al. (2004).

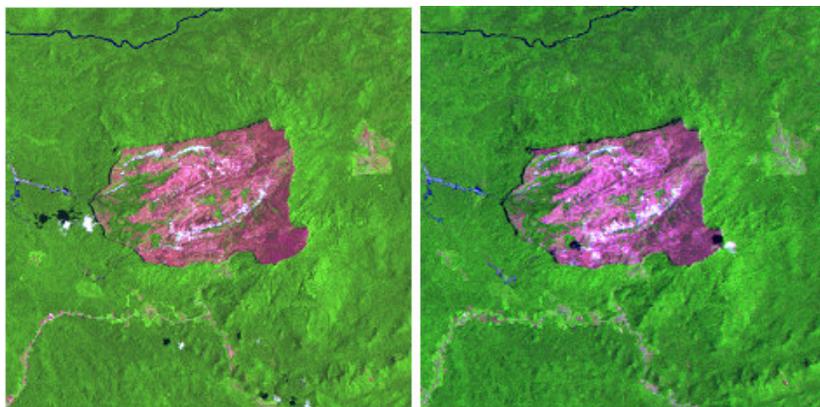


Figura 52 – Imagens Landsat-TM da área de estudo em 1994 e 1996 respectivamente. Composições coloridas em cores naturais.

As seis bandas espectrais do sensor TM com resolução espacial de 30m foram utilizadas na geração das imagens de fração, sendo os *endmembers*: vegetação, solo exposto e sombra (Figura 53). As duas imagens foram adquiridas sob altos níveis de elevação solar, o que deveria minimizar efeitos de sombra. No entanto, ao compará-las, a imagem correspondente a 1996 (t_2) apresenta maior sombreamento.

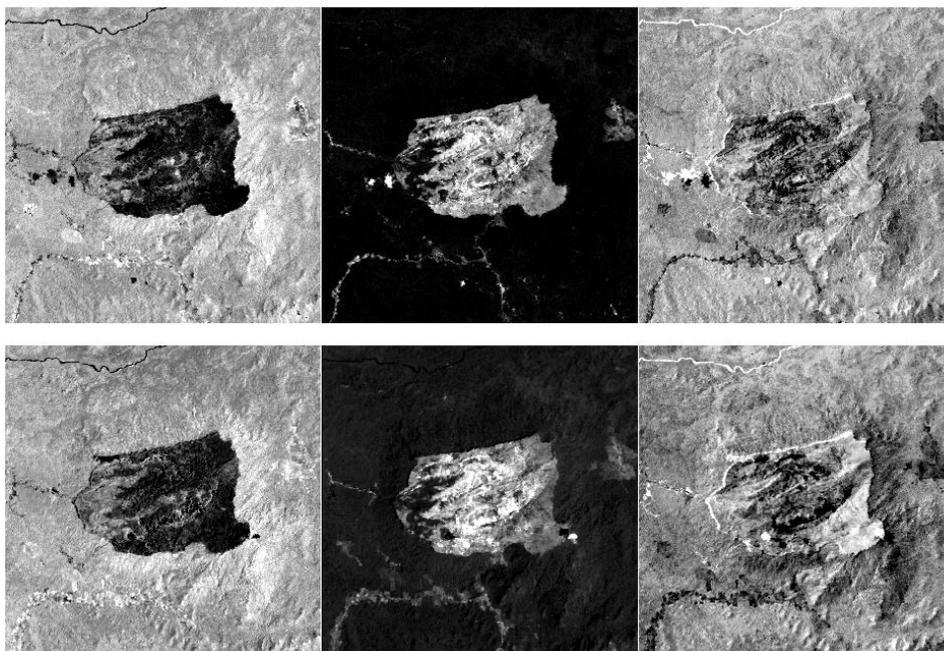


Figura 53 – Imagens de fração considerando três *endmembers* – vegetação, solo exposto e sombra – para as duas imagens do experimento R2. Acima o recorte da cena em t_1 e abaixo em t_2 .

Ambas as imagens contam com a presença de nuvens facilmente identificáveis por meio de análise visual. O classificador rígido, independentemente do nível de confiança adotado, identificou-as com sucesso, assim como as respectivas áreas de sombra. Os mapas binários gerados pelo classificador rígido, com e sem filtragem morfológica, são apresentados na Figura 54.

Comparando os mapas binários da Figura 54, referentes aos níveis de confiança de 90 e 95%, com os mapas de mudança produzidos por Haertel, Shimabukuro e Almeida-Filho (2004), percebe-se grande semelhança. Contudo os mapas produzidos pela presente proposta, especialmente aqueles com filtragem morfológica, são menos ruidosos em decorrência da realização do teste de hipóteses.

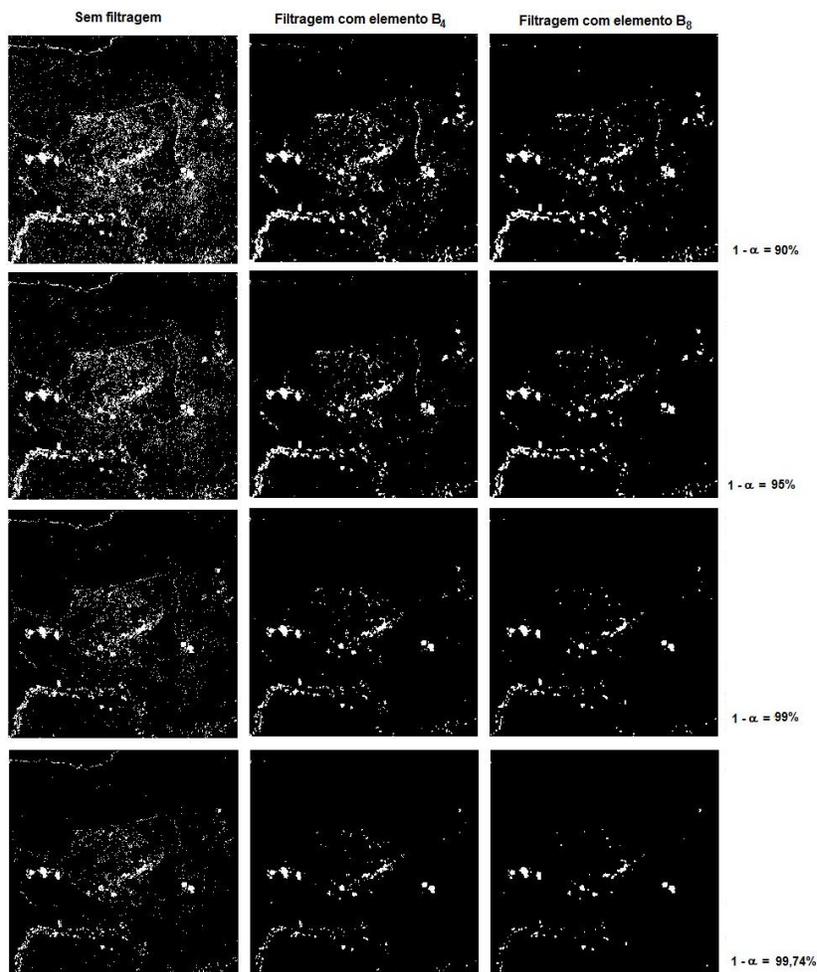


Figura 54 – Mapas de mudança resultantes da proposta rígida no experimento R2 com quatro diferentes níveis de confiança, sem filtragem e com filtragem morfológica utilizando os elementos B_4 e B_8 .

A imagem-produto entre o mapa de mudança binário ($1-\alpha=95\%$; B_8) e a imagem de diferenças foi submetida a uma análise de agrupamento com $K=4$. O mapa temático de mudanças resultante da análise de agrupamento é apresentado na Figura 55, sendo os centróides dos *clusters* os seguintes:

- Cluster 1:* [+0,3101; -0,1959; -0,1142];
- Cluster 2:* [-0,1020; +0,3454; -0,2428];
- Cluster 3:* [+0,0775; -0,4328; +0,3552];
- Cluster 4:* [+0,2264; +0,1374; -0,3639].

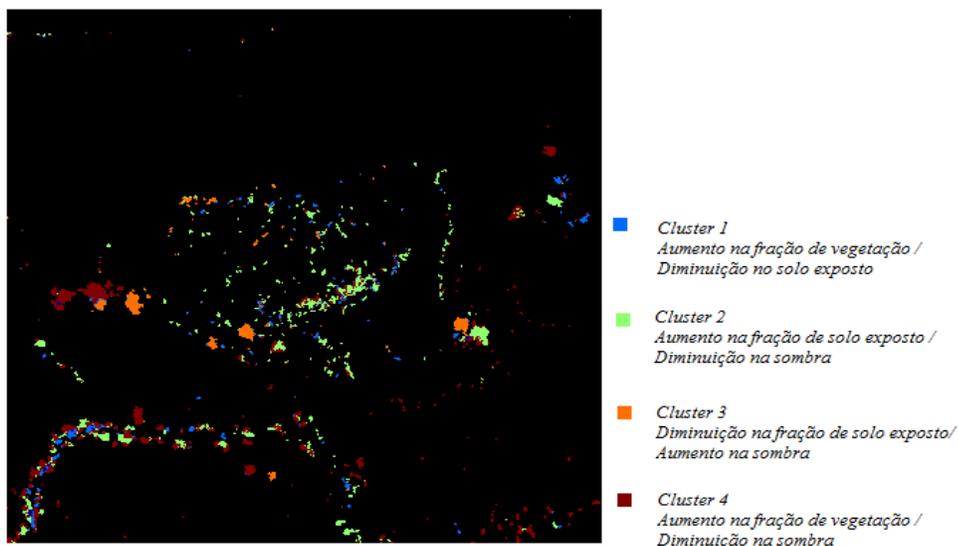


Figura 55 - Mapa temático construído a partir da análise de agrupamento para identificação dos tipos de mudança – Experimento R2

O mapa temático identifica importantes classes de mudança, considerando o período de 1994-1996. A parte inferior da imagem revela a existência de atividade agrícola ao longo de uma estrada. A dinâmica de uso do solo para fins de agricultura faz com que os *clusters* associados ao aumento na fração de vegetação e ao aumento no solo exposto se intercalem ao longo da estrada. Na região central do platô, uma extensa área associada ao *Cluster 2* é atribuída à atividade de mineração.

O experimento R2 também foi submetido ao procedimento de classificação suave. A Tabela 7 apresenta as estimativas do modelo de regressão logística utilizadas para geração dos mapas de probabilidade (Figura 56). A classificação suave produziu resultados menos ruidosos do que os mapas binários sem filtragem e, ao mesmo tempo, parecem preservar mais informações do que os mapas pós-filtragem. Áreas mais sombreadas em t_2 do que em t_1 , por exemplo, aparecem com uma pequena probabilidade de pertencer à classe ω_c , o que é razoável. O procedimento rígido seguido de filtragem morfológica simplesmente as eliminou do mapa de mudanças.

Tabela 7 – Estimativas para o modelo de regressão logística utilizado no experimento R2 para classificação suave com diferentes níveis de confiança

$(1-\alpha)\times 100$	$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$
90	-6,547	18,707	21,722
91	-6,749	19,312	21,378
92	-6,823	19,121	20,725
93	-6,891	19,320	19,762
94	-7,122	19,651	19,974
95	-7,088	17,897	19,264
96	-7,133	18,204	17,829
97	-7,387	17,113	18,335
98	-7,945	19,155	18,545
99	-7,881	18,208	15,703
99,74	-8,109	16,783	14,333

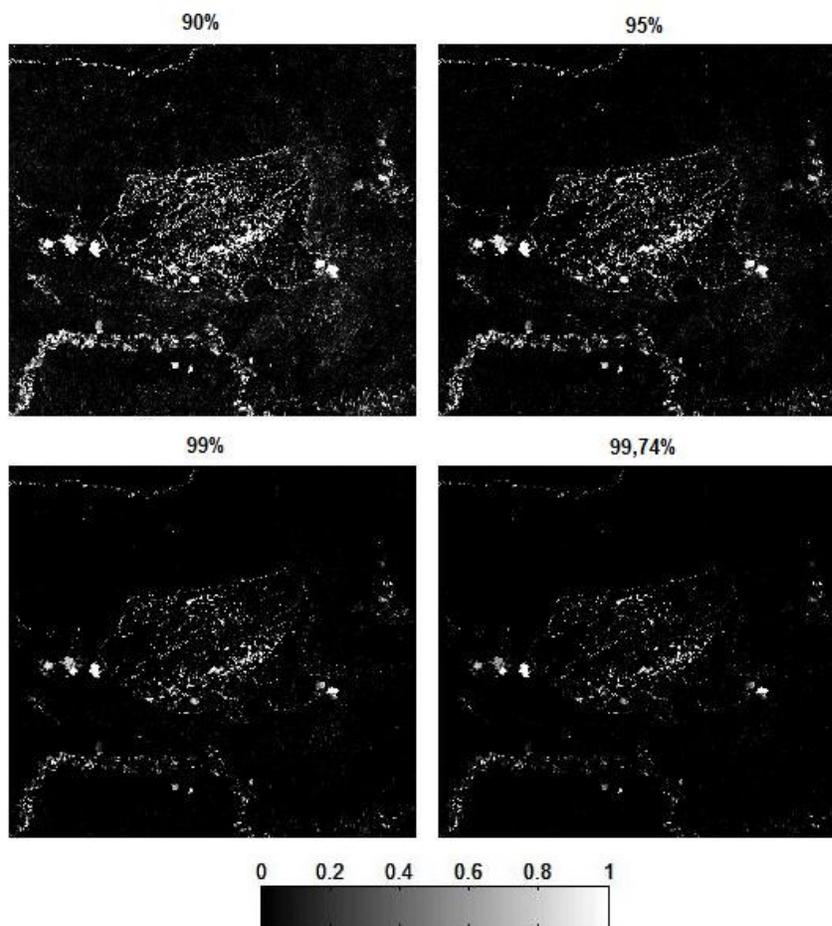


Figura 56 – Mapas da probabilidade de pertencer à classe ω_c para diferentes níveis de confiança

Para finalizar o experimento R2, mapas dos graus de pertinência à classe ω_c foram produzidos (Figura 57).

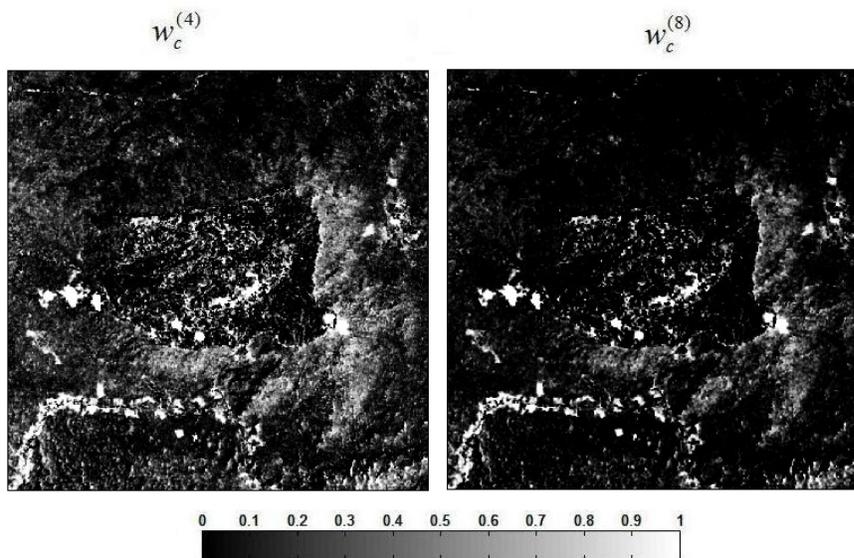


Figura 57 – Mapas dos graus de pertinência à classe ω_c utilizando dois esquemas de vizinhança

Os mapas dos graus de pertinência identificam na cor branca: a) as nuvens e suas sombras, b) a região central do platô associada à atividade de mineração, c) as áreas ao longo da estrada na qual são desenvolvidas atividades agrícolas e d) áreas de desflorestamento / rebrota. Os graus de pertinência intermediários (níveis de cinza) indicam mudanças mais sutis, especialmente associadas à sombra. A Figura 58 apresenta a distribuição dos graus de pertinência presentes na imagem na forma de histogramas. Claramente, há maior quantidade de pixels com graus de magnitude baixa.

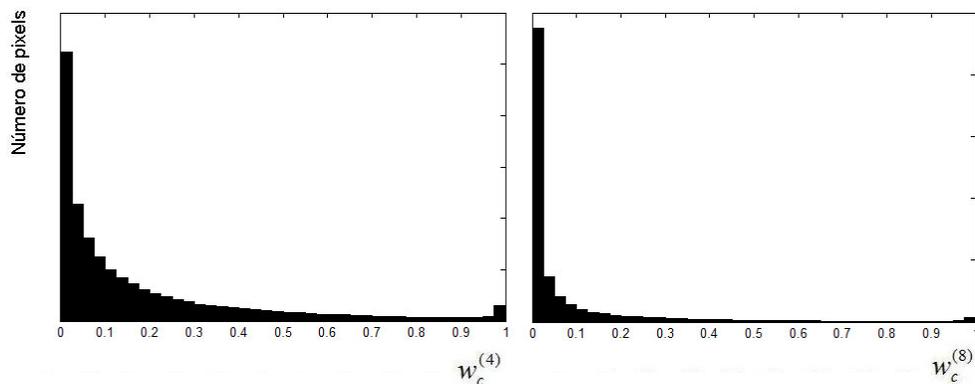


Figura 58 – Histograma dos graus de pertinência dos mapas CM_{fuzzy} utilizando dois esquemas de vizinhança

4.2.3 Experimento R3

O experimento R3 diferencia-se dos anteriores, pois foi realizado a partir de um mosaico de duas cenas Landsat-TM em cada data de aquisição. As duas imagens utilizadas neste experimento consistem de recortes de 1000×1000 pixels que englobam parte das cenas correspondentes aos pontos 78 e 79 da órbita 220. O mosaico foi necessário para que o recorte contemplasse parte da área atingida pelos eventos de inundação e movimentos de massa que ocorreram no estado de Santa Catarina, em novembro de 2008.

A Figura 59 apresenta os recortes na forma de composições coloridas RGB, nas quais se percebe a planície ao longo do rio Itajaí-Açú amplamente habitada e também utilizada para fins de agricultura e pecuária. O município de Ilhota localiza-se na margem norte do rio Itajaí-Açú, ao longo da qual se situa a rodovia BR-470. Na margem sul, os principais municípios são Gaspar e Blumenau. A pequena mancha urbana no centro-norte da imagem corresponde ao município de Luis Alves.

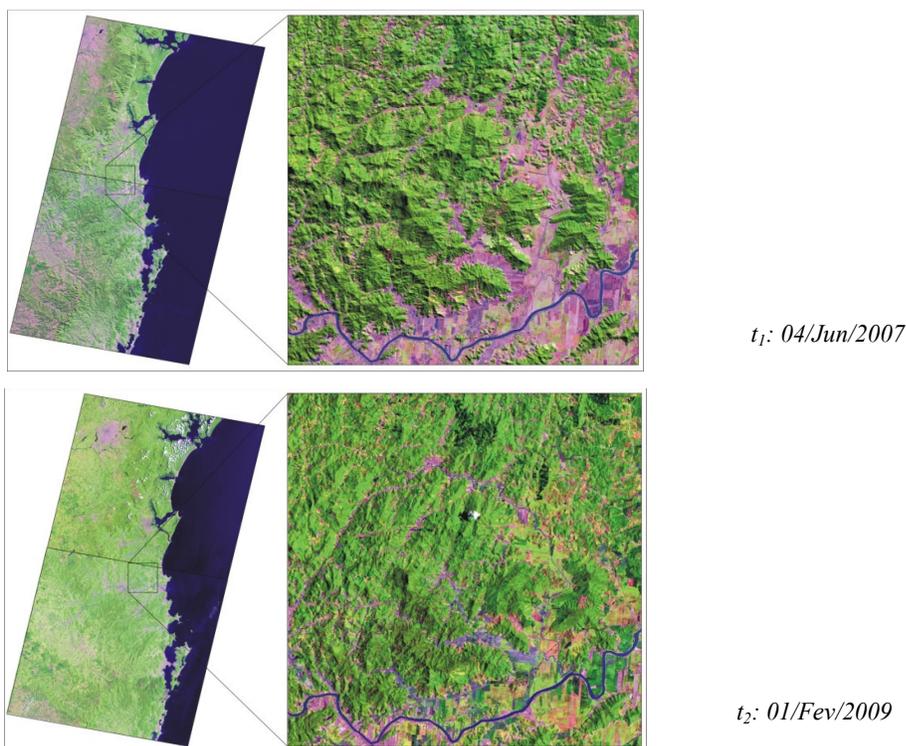


Figura 59 – Cenas Landsat-TM correspondentes à órbita-ponto 220/78 e 79 e detalhes dos recortes efetivamente utilizados no experimento R3

Para a geração das imagens de fração foram consideradas todas as seis bandas espectrais com resolução espacial de 30m disponibilizadas pelo sensor TM. Quatro

endmembers foram considerados: vegetação, solo exposto, água e sombra. Julgou-se necessária a inclusão do componente sombra devido à presença de áreas sombreadas, especialmente na imagem de fevereiro. A Figura 60 apresenta as imagens fracionadas.

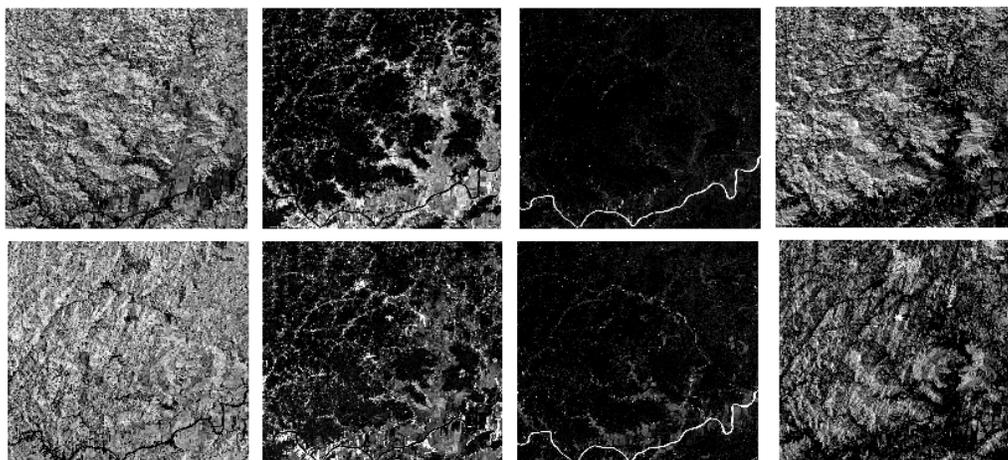


Figura 60 – Imagens de fração considerando quatro *endmembers* – vegetação, solo exposto, água e sombra – para as duas imagens do experimento R3. Acima o recorte da cena em t_1 e abaixo em t_2 .

Os mapas de mudança binários gerados pelo classificador rígido para quatro níveis de confiança são apresentados na Figura 61. A análise visual dos mapas de mudança novamente indicou que os níveis de confiança de 90% e 95% associados aos filtros morfológicos produziram os melhores resultados. A interpretação dos resultados não foi imediata, visto que existem diferentes classes de mudança presentes na imagem. Mesmo tendo ocorrido eventos de inundação e deslizamento de grandes proporções com ampla repercussão na mídia, a distância de três meses entre os eventos (Nov/2008) e a data de aquisição da cena (Fev/2009), associada ao tamanho diminuto das cicatrizes em relação à resolução do sensor TM, dificultam a interpretação dos resultados. Apesar dessas dificuldades, uma análise de agrupamento com o algoritmo K -médias ($K=4$), realizada a partir da imagem binária com nível de confiança de 90% e filtro morfológico B_8 , permitiu uma interpretação dos resultados facilitada. A Figura 62 apresenta o mapa temático dos *clusters* cujos centróides são:

Cluster 1: [+0,5508; -0,0699; -0,0075; -0,4735];

Cluster 2: [+0,3987; -0,6594; +0,1069; +0,1538];

Cluster 3: [-0,3108; +0,6251; +0,0388; -0,3531];

Cluster 4: [-0,0314; -0,2179; +0,3038; -0,0545].

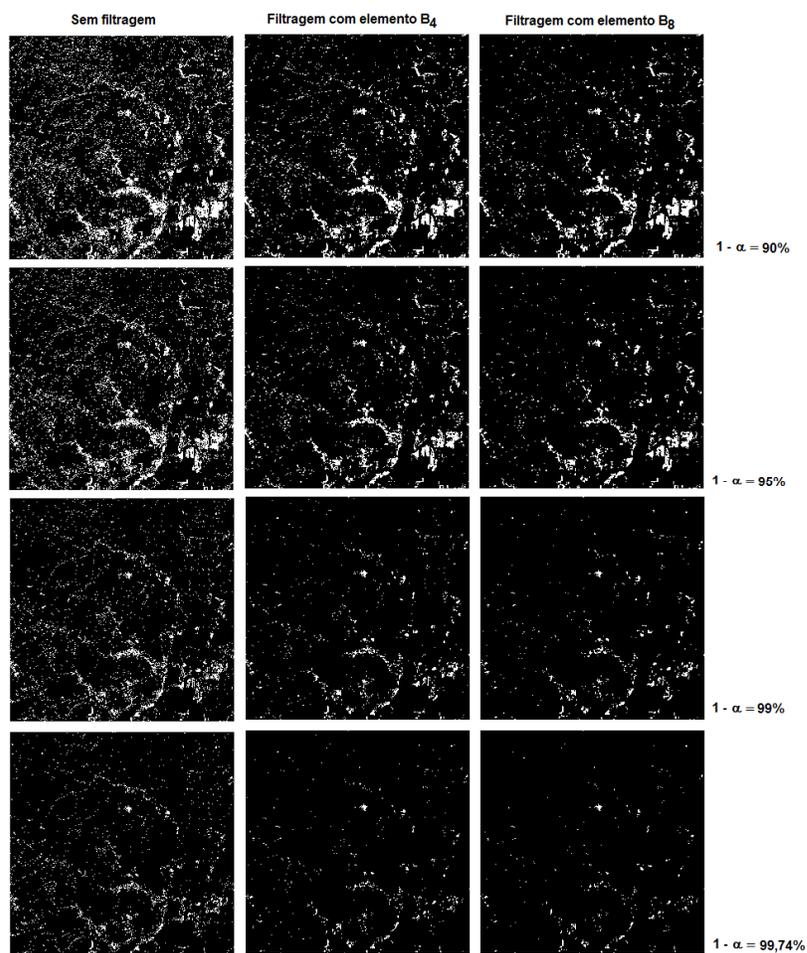


Figura 61 – Mapas de mudança resultantes da proposta rígida no experimento R3 com quatro diferentes níveis de confiança, (a) sem filtragem, (b) com filtragem morfológica utilizando o elemento B₄ e (c) com filtragem morfológica utilizando o elemento B₈.

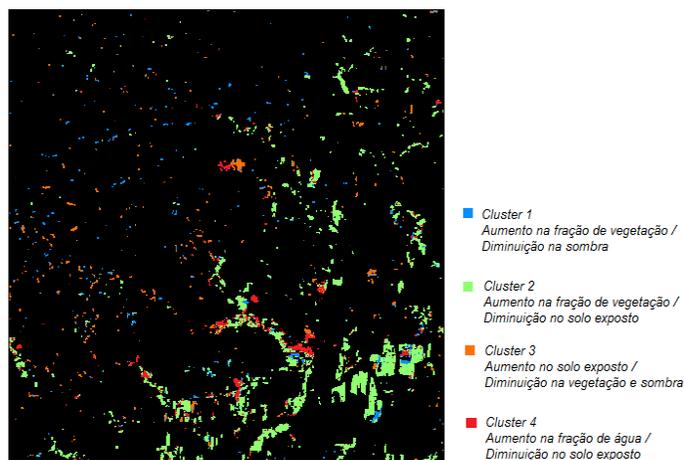


Figura 62 - Mapa temático construído a partir da análise de agrupamento para identificação dos tipos de mudança – Experimento R3

A Figura 62 revela que o *Cluster 2* é o mais abundante na imagem. Ele representa áreas com aumento na fração de vegetação e decréscimo na fração de solo exposto. Esse agrupamento revela, principalmente, áreas de cultivo de arroz que, em fevereiro (t_2), se encontravam irrigadas e, em junho, estavam em fase de preparo do terreno. O *Cluster 3*, também abundante, está relacionado à atividade agrícola, entretanto ele identifica áreas de escorregamentos que ocorreram nas encostas dos morros, cujas cicatrizes foram percebidas pelo aumento na fração de solo exposto em t_2 . O *Cluster 1* identificou diferenças nos efeitos de sombra em áreas de vegetação densa, e, por fim, o *Cluster 4* reflete a dinâmica de uso do solo para fins agrícolas, com o aumento na fração de água e diminuição na fração de solo exposto.

O experimento R3 seguiu com a flexibilização dos resultados da classificação rígida por meio da regressão logística. Os parâmetros estimados com diferentes níveis de confiança são apresentados na Tabela 8. Nesse experimento, houve a necessidade de estimação de um parâmetro a mais do que nos anteriores, pois, devido à seleção de quatro *endmembers*, a dimensionalidade aumentou para $v=3$.

Tabela 8 – Estimativas para o modelo de regressão logística utilizado no experimento R3 para classificação suave com diferentes níveis de confiança

$(1-\alpha)\times 100$	$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_3$
90	-6,4243	6,5495	7,5024	2,2681
91	-6,5265	6,4483	7,5270	2,4359
92	-6,5787	6,1114	7,5285	2,6304
93	-6,7279	5,8859	7,7263	2,2598
94	-6,8260	5,5811	7,6324	2,5183
95	-7,0267	4,8514	8,1627	2,5352
96	-7,2545	4,3373	8,5036	2,3558
97	-7,5331	3,7045	8,9953	2,2028
98	-8,0779	2,8462	9,7943	2,1507
99	-9,4169	1,7467	11,4678	2,3472
99,74	-12,0754	-0,2946	14,3230	2,0303

Os mapas de probabilidade gerados para níveis de confiança entre 90 e 94% são muito semelhantes devido à pequena variação nos parâmetros estimados. A partir de 95%, os parâmetros começam a variar a taxas crescentes, conforme pode ser visualizado na Figura 63. Quatro mapas de probabilidade de pertencer à classe ω_c são apresentados na Figura 64.

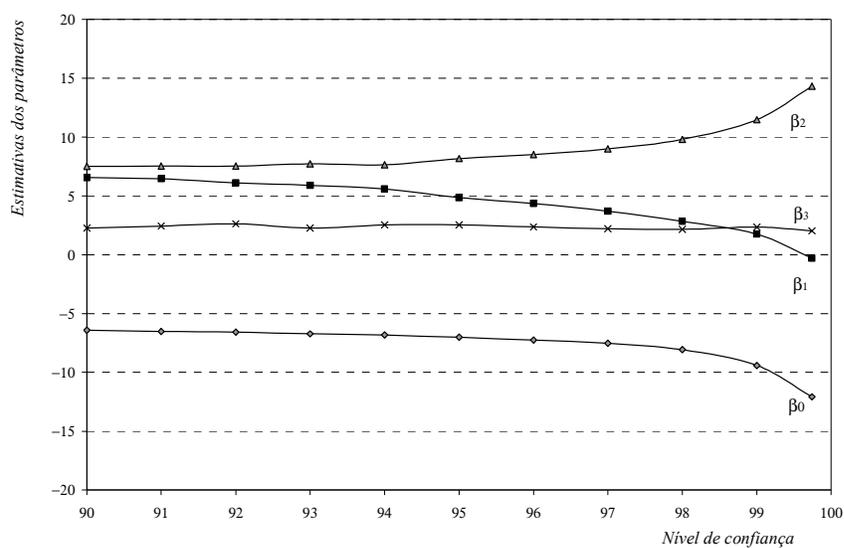


Figura 63– Variação das estimativas dos parâmetros do modelo de regressão logística em função do nível de confiança adotado – Experimento R3

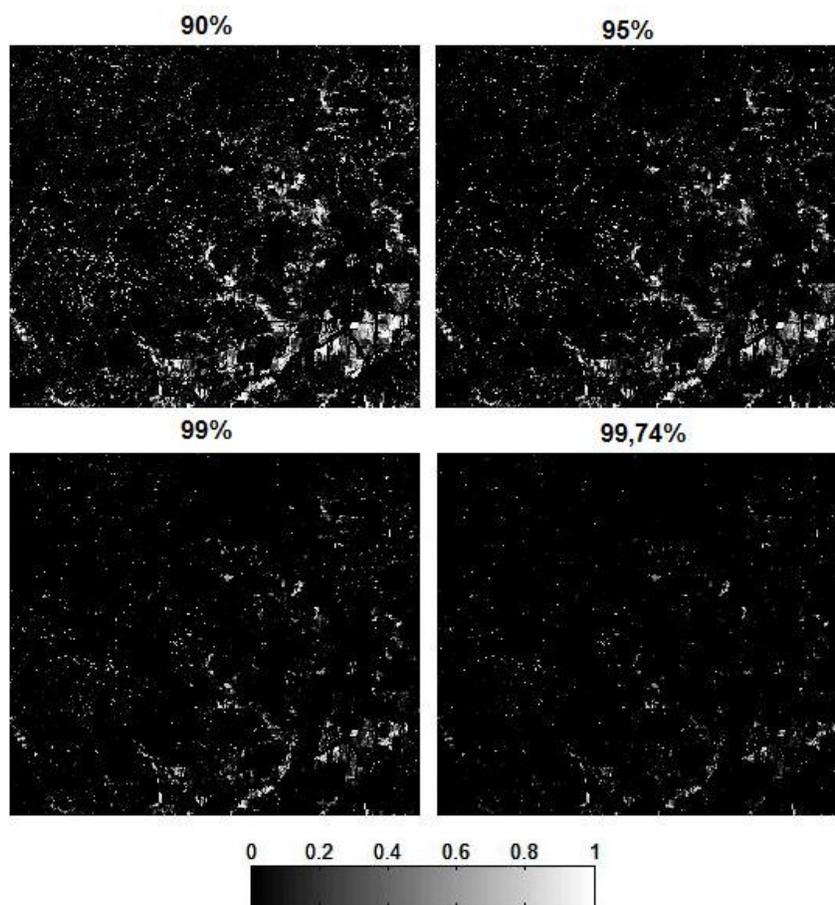


Figura 64– Mapas da probabilidade de pertencer à classe ω_c para diferentes níveis de confiança

Uma análise visual dos mapas de probabilidade gerados no experimento R3 indica que os resultados para níveis de confiança iguais ou inferiores a 95% tendem a apresentar mais detalhes do que aqueles resultantes da classificação rígida. Os níveis de confiança de 99 e 99,74% produziram mapas muito simplificados e com baixa taxa de detecção.

Os últimos resultados do experimento R3 foram os mapas de mudanças *fuzzy* (CM_{fuzzy}) gerados com os dois esquemas de vizinhança propostos. Os resultados, apresentados na Figura 65, foram semelhantes aos mapas de probabilidade com níveis de confiança de 90% e 95%, mas os mapas *fuzzy* novamente parecem ter preservado mais informações referentes às mudanças ocorridas de t_1 para t_2 .

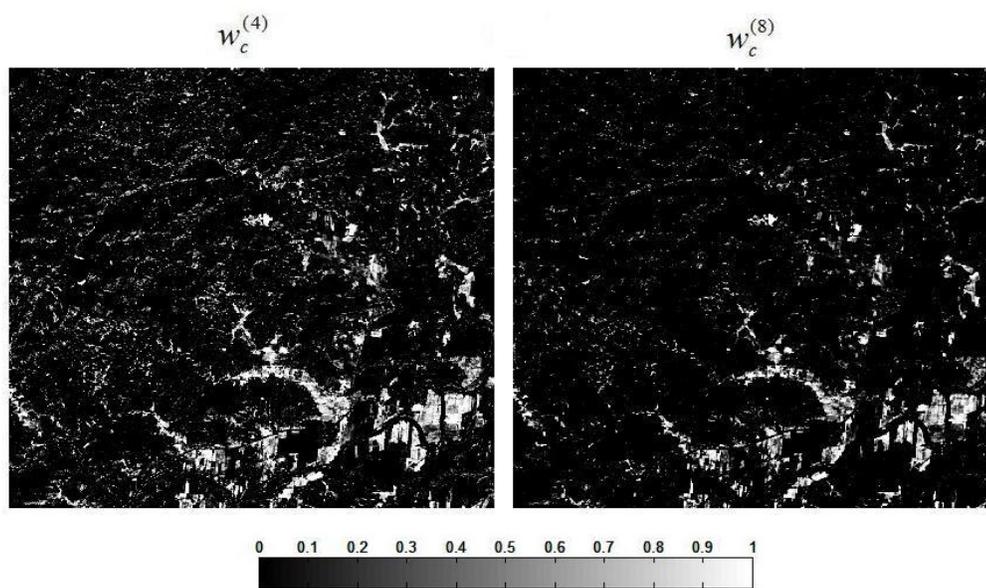


Figura 65 – Mapas dos graus de pertinência à classe ω_c utilizando dois esquemas de vizinhança

4.3 ANÁLISE COMPARATIVA

A análise comparativa entre os resultados produzidos pelas propostas rígida, suave e *fuzzy* não é imediata devido às diferenças conceituais entre elas. Nos dois experimentos com imagens sintéticas havia o conhecimento dos mapas de referência, no entanto apenas no experimento S2 houve controle gradual das alterações. Isso significa que o mapa de referência do experimento S1 era binário e o do experimento S2 considerava níveis intermediários.

Quando possível, a medida adotada para comparação entre os resultados foi o Erro Quadrático Médio (MSE). Os MSEs das classificações rígida, suave e *fuzzy* foram produzidos por meio das Equações 29, 30 e 31:

$$MSE_{Rigida} = (NM)^{-1} \sum_{i=1}^N \sum_{j=1}^M [CM(i, j) - CM_{Ref}(i, j)]^2, \quad (29)$$

$$MSE_{Suave} = (NM)^{-1} \sum_{i=1}^N \sum_{j=1}^M [P(\omega_c | \mathbf{d}(i, j)) - CM_{Ref}(i, j)]^2, \quad (30)$$

$$MSE_{Fuzzy} = (NM)^{-1} \sum_{i=1}^N \sum_{j=1}^M [w_{ij} - CM_{Ref}(i, j)]^2. \quad (31)$$

No experimento S1, a comparação entre os procedimentos *rígido* e *suave* foi realizada, mesmo conhecendo-se apenas o mapa de referência binário. Por esse motivo, a comparação deve ser feita com cautela. A Tabela 9 apresenta os resultados dos MSE para essas duas propostas.

Tabela 9 – Valores do Erro Quadrático Médio (MSE) para os mapas de mudança gerados pelos classificadores rígido e suave no experimento S1 ($\times 10^{-2}$)

$(1-\infty) \times 100$	SNR (dB)	Classificador Rígido			Classificador Suave
		Sem filtragem	Filtragem com B_4	Filtragem com B_8	
90	10	8,914	0,073	0,073	0,107
90	20	2,855	0,017	0,028	0,045
90	30	0,006	0,010	0,013	0,029
90	40	0,005	0,007	0,010	0,025
95	10	5,089	0,074	0,080	0,106
95	20	1,251	0,021	0,034	0,044
95	30	0,007	0,011	0,016	0,027
95	40	0,005	0,008	0,013	0,026
99	10	1,160	0,088	0,088	0,108
99	20	0,152	0,034	0,046	0,050
99	30	0,010	0,017	0,028	0,030
99	40	0,009	0,015	0,024	0,024
99,74	10	0,383	0,094	0,096	0,115
99,74	20	0,046	0,043	0,051	0,053
99,74	30	0,012	0,020	0,034	0,034
99,74	40	0,011	0,019	0,032	0,025

Os resultados indicam que, de uma forma geral, o classificador rígido seguido de filtragem morfológica apresentou resultados superiores aos gerados pela proposta suave em

S1. Esse resultado não deixa de ser esperado visto que se está comparando uma proposta suave contra um mapa binário. O elemento estruturante \mathbf{B}_4 apresentou valores de MSE menores ou iguais aos alcançados pelo elemento \mathbf{B}_8 .

No intuito de se avaliar os resultados da proposta *fuzzy* em S1, foram construídos gráficos do tipo *boxplot* nos quais se avaliou a variação dos graus de pertinência nas regiões correspondentes à classe ω_c (1) e ω_{nc} (0). Foram escolhidos dois valores de SNR extremos (10 e 40dB) para apresentação dos resultados na Figura 66. Os resultados mostram que os graus de pertinência resultaram muito baixos ou nulos nas regiões onde não foram inseridas mudanças, o que é altamente desejável. No entanto percebe-se que, nas regiões de alteração, especialmente na imagem ruidosa e com esquema de 8 vizinhos, os graus de pertinência apresentam grande variação. Por outro lado, o esquema com 4 vizinhos sob SNR=40dB praticamente reproduziu o mapa de referência binário.

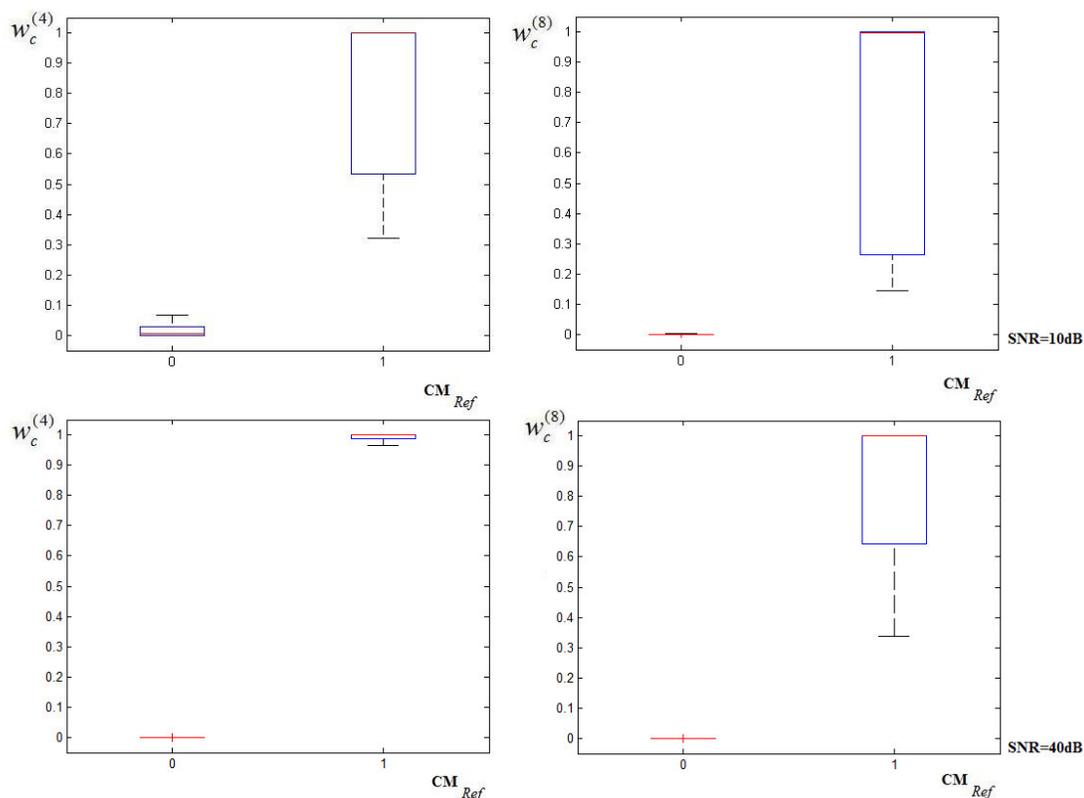


Figura 66 – *Boxplots* dos graus de pertinência gerados pelo classificador *fuzzy* no experimento S1 sob dois níveis de SNR conforme o mapa de referência ($\omega_c=1$ e $\omega_{nc}=0$)

O experimento S2 possibilitou uma comparação mais efetiva entre as três propostas, visto que o mapa de referências continha a informação das mudanças graduais inseridas na imagem. A Tabela 10 sintetiza os resultados do MSE encontrados nas três propostas sob diferentes valores de SNR.

Tabela 10 – Valores do Erro Quadrático Médio (MSE) para os mapas de mudança gerados pelos classificadores rígido, suave e *fuzzy* no experimento S2 ($\times 10^{-2}$)

$(1-\infty) \times 100$	SNR (dB)	Classificador Rígido			Classificador Suave	Classificador Fuzzy	
		Sem filtragem	Filtragem com B_4	Filtragem com B_8		Esquema de 4 vizinhos	Esquema de 8 vizinhos
90	5	11,601	0,494	0,627	0,879	0,869	0,549
90	10	6,122	0,420	0,388	0,369	0,488	0,356
90	15	0,603	0,611	0,616	0,534	0,557	0,539
95	5	5,482	0,619	0,800	0,898	0,869	0,549
95	10	2,516	0,369	0,359	0,344	0,488	0,356
95	15	0,454	0,463	0,467	0,416	0,557	0,539
99	5	2,052	0,834	0,956	0,946	0,869	0,549
99	10	0,871	0,344	0,332	0,300	0,488	0,356
99	15	0,455	0,464	0,467	0,413	0,557	0,539
99,74	5	1,326	0,990	1,020	0,999	0,869	0,549
99,74	10	0,464	0,328	0,329	0,276	0,488	0,356
99,74	15	0,433	0,435	0,415	0,367	0,557	0,539

De uma forma geral, o esquema com oito vizinhos da proposta *fuzzy* foi superior às demais. Exceto no procedimento rígido sem filtragem, todos os demais apresentaram melhores resultados para SNR=10dB. Isso ocorre porque com 15dB os classificadores detectam até mesmo as diferenças de magnitude baixa, atribuindo $CM(i,j)=1$ no caso do classificador rígido, probabilidades altas no classificador suave e graus de pertinência elevados na proposta *fuzzy*. Essas superestimativas elevam o MSE. Para SNR=5dB ocorre o contrário. A maior variabilidade faz com que alterações de menor magnitude desapareçam, derrubando a taxa de detecção e subestimando a área de mudança, o que também eleva o MSE.

Outras constatações importantes decorrem da análise dos resultados de S2:

- para SNR=15dB o classificador suave foi sempre superior aos demais;
- para SNR=5dB (alto nível de ruído), os mapas *fuzzy* apresentaram sempre menor MSE do que o classificador suave;
- o procedimento rígido sem filtragem só apresenta resultados comparados aos demais para SNR=15dB; e
- a filtragem morfológica é essencial no classificador rígido para $SNR \leq 10$ dB.

Nos experimentos R1–R3 não há disponibilidade de mapa de referência, então a comparação das probabilidades e graus de pertinência produzidos nas classificações suave e *fuzzy* foi realizada por meio de análise de correlação. A comparação desses resultados com a proposta rígida se deu por meio de *boxplots*.

A Tabela 11 apresenta os valores do coeficiente de correlação de Pearson entre as probabilidades estimadas na classificação suave e os graus de pertinência *fuzzy* $w^{(4)}$ e $w^{(8)}$.

Tabela 11 – Coeficientes de correlação entre as probabilidade estimadas pelo algoritmo de classificação suave e os graus de pertinência *fuzzy* $w^{(4)}$ e $w^{(8)}$ nos experimentos R1-R3

$(1-\alpha) \times 100$	Experimento R1		Experimento R2		Experimento R3	
	Suave vs. $w^{(4)}$	Suave vs. $w^{(8)}$	Suave vs. $w^{(4)}$	Suave vs. $w^{(8)}$	Suave vs. $w^{(4)}$	Suave vs. $w^{(8)}$
90	0,760	0,686	0,626	0,626	0,749	0,719
91	0,753	0,681	0,615	0,620	0,746	0,720
92	0,747	0,677	0,600	0,610	0,741	0,721
93	0,739	0,670	0,586	0,601	0,735	0,721
94	0,729	0,663	0,570	0,589	0,727	0,720
95	0,717	0,654	0,550	0,575	0,718	0,721
96	0,700	0,643	0,539	0,567	0,706	0,717
97	0,681	0,633	0,520	0,551	0,692	0,712
98	0,659	0,628	0,490	0,526	0,666	0,697
99	0,622	0,631	0,455	0,496	0,609	0,656

A análise de correlação mostra que há uma associação moderada entre as probabilidades estimadas na classificação suave e os graus de pertinência *fuzzy*. A magnitude do coeficiente de correlação tende a cair à medida que aumenta o nível de confiança. O experimento R2 foi aquele no qual as correlações foram mais baixas. O motivo desse resultado pode ser atribuído ao fato de que a classificação suave produziu probabilidades de pertença à classe ω_c mais baixas e com maior variabilidade do que os graus de pertinência *fuzzy*.

As Figuras 67 e 68 apresentam os gráficos do tipo *boxplot* para as probabilidades e graus de pertinência de acordo com os resultados produzidos pela classificação rígida seguida de filtragem morfológica com o operador \mathbf{B}_4 nos experimentos R1 e R2, respectivamente.

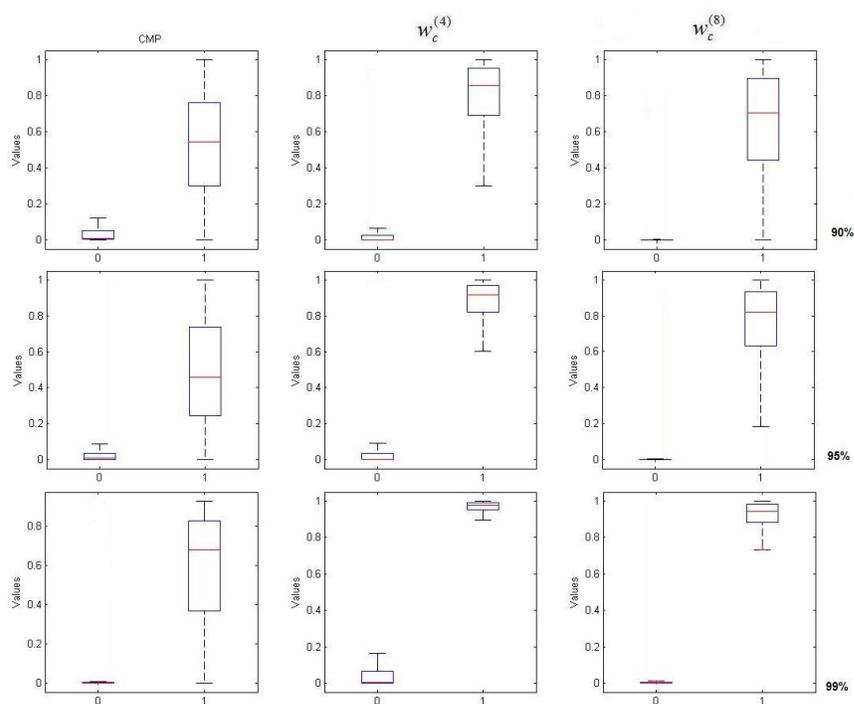


Figura 67 – Boxplots das probabilidades e graus de pertinência *fuzzy* de acordo com o resultado da classificação rígida – Experimento R1

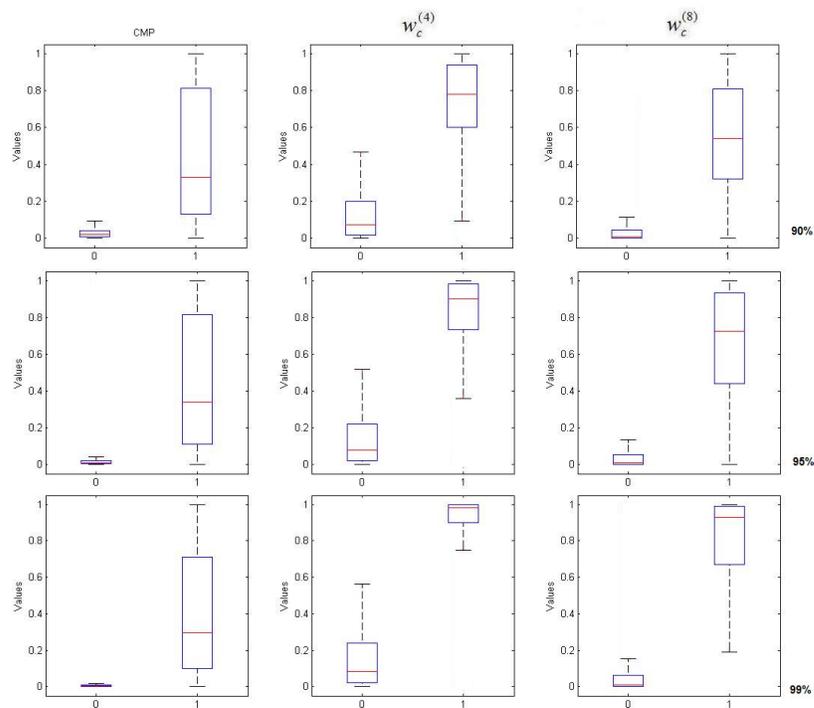


Figura 68 – Boxplots das probabilidades e graus de pertinência *fuzzy* de acordo com o resultado da classificação rígida – Experimento R2

Os resultados mostram que as probabilidades $P(\omega_c | \mathbf{d})$ variam mais do que os graus de pertinência *fuzzy* dentre aqueles pixels classificados como ω_c no procedimento rígido. Por outro lado, quando a classificação rígida associa o pixel à classe ω_{nc} , foram os graus de pertinência $w_c^{(4)}$ que apresentaram maior variabilidade. À medida que se aumenta o nível de confiança, $w_c^{(4)}$ e $w_c^{(8)}$ tendem a migrar para os valores extremos (0 e 1). No caso da classificação suave, esse fenômeno é menos perceptível.

A Figura 69 mostra que as considerações referentes aos experimentos R1 e R2 também se aplicam ao experimento R3.

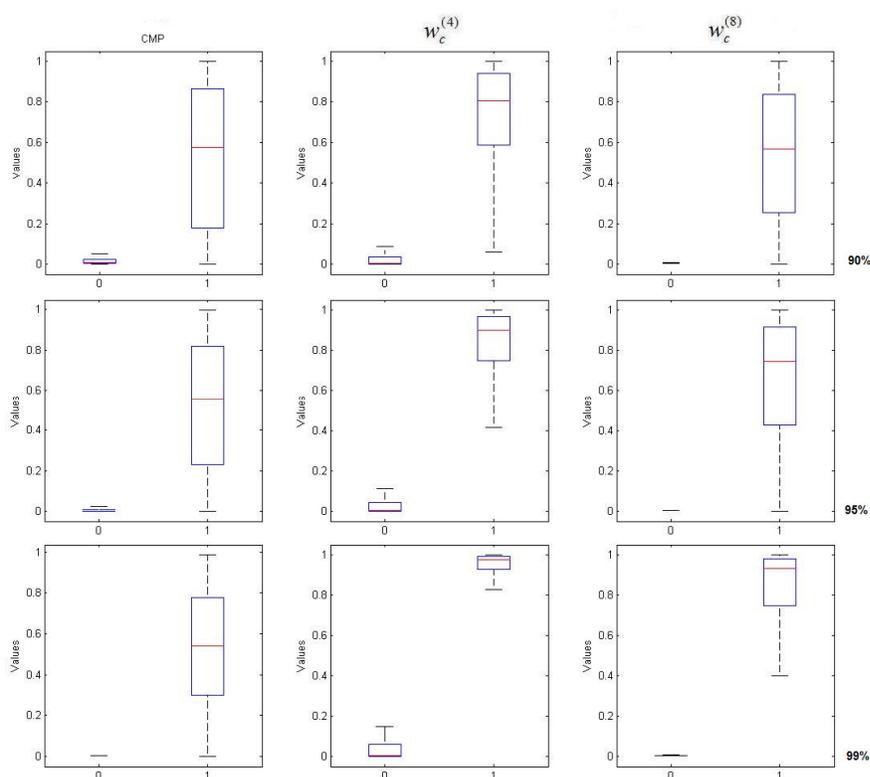


Figura 69 – Boxplots das probabilidades e graus de pertinência *fuzzy* de acordo com o resultado da classificação rígida – Experimento R3

As diferenças observadas entre as probabilidades e os graus de pertinência nos *boxplots* ajudam a explicar as correlações de magnitude apenas moderada entre elas. A maior variabilidade percebida nos resultados da classificação suave pode ser atribuída ao fato de não ter sido utilizada informações de vizinhança nesta proposta.

5. CONCLUSÃO

Neste trabalho, três propostas de algoritmos para detecção de mudanças na superfície terrestre a partir de imagens de fração foram apresentadas, testadas e avaliadas. Embora haja particularidades e até mesmo diferenças conceituais entre elas, as propostas têm em comum a operação no espaço de diferenças de frações, sobre um substrato probabilístico e estatístico, utilizando a distância de Mahalanobis. Outras características comuns são:

- a pequena necessidade de intervenção do analista para a geração dos mapas de mudança binários, de probabilidade ou de graus de pertinência;
- a capacidade de operação sob qualquer dimensionalidade, dispensando a seleção de componentes.

Os resultados apontam para a viabilidade das propostas. Entretanto cada uma delas revelou vantagens e desvantagens durante a fase experimental, as quais são discutidas a seguir.

A proposta *rígida* gerou, no experimento S1, mapas de mudança binários que praticamente reproduziram o mapa de referência, desde que associado a um procedimento de filtragem. Ao analisar as curvas ROC de 10 e 20dB, constatou-se que o nível de confiança de 90% produziu os piores resultados se operacionalizado sem filtragem. Paradoxalmente, o melhor desempenho foi obtido com esse mesmo nível de confiança, quando associado ao filtro morfológico com o elemento **B**₄. O nível de confiança de 95% também produziu bons resultados, quando associado ao elemento **B**₄. Apesar de não contar com medidas quantitativas para avaliação dos resultados, os mapas de mudança binários produzidos nos experimentos R1, R2 e R3 com estes dois níveis de confiança, foram considerados aqueles que melhor reproduziram a realidade. Níveis de confiança iguais ou superiores a 99%, especialmente se associados à filtragem morfológica, baixaram a DR e, por outro lado, se não forem submetidos à filtragem, tendem a apresentar altas taxas de FA. A proposta *rígida*, combinada ao algoritmo de *clustering*, também possibilita a confecção de mapas temáticos de mudanças, os quais são de fácil interpretação e de grande valia em estudos de monitoramento temporal.

A proposta de algoritmo *suave* para detecção de mudanças apresentou resultados muito superiores à proposta rígida, desde que esta última seja conduzida sem filtragem e sob

altos níveis de ruído. No entanto, quando associado à filtragem morfológica, o classificador rígido mostrou-se superior ao suave. Mesmo que o classificador suave tenha produzido resultados que, de uma forma geral, são menos acurados do que os gerados pela classificação rígida com filtragem, não se pode deixar de destacar os mapas de probabilidade por ele gerados. Um mapa de probabilidade tem a capacidade de apresentar, numa escala de cinza, níveis intermediários da probabilidade de pertencer à classe ω_c . A equação da regressão logística permite, ainda, que o pesquisador interprete os parâmetros e realize simulações.

A proposta *fuzzy* é do ponto de vista teórico, aquela que melhor representa a realidade do problema de detecção de mudanças a partir de imagens de satélites com baixa, média ou alta resolução. A sintonia entre a lógica *fuzzy* e o conceito de pixel mistura é inegável. No entanto, a validação de uma proposta *fuzzy* é difícil uma vez que não se dispõe de informações de mudança ao nível de subpixel. O experimento S2 permitiu uma melhor avaliação dos resultados *fuzzy* e, como era esperado, o erro associado foi menor do que o obtido com o classificador rígido, o que pode ser considerado um bom resultado. Nos experimentos com imagens reais, os mapas *fuzzy* foram satisfatórios, captando informações que não constam dos mapas gerados pelas propostas rígida e suave. A análise dos resultados mostrou que, quando a classificação rígida associa um pixel à ω_{nc} ($CM(i,j)=0$), os graus de pertinência $w^{(+)}$ e $w^{(-)}$ também foram muito próximos de zero. No caso de $CM(i,j)=1$, a variabilidade nos graus de pertinência foi maior, com a mediana aumentando à medida que se adota níveis de confiança mais elevados.

5.1 CONTRIBUIÇÕES DESTA TESE

Apontar os aspectos de ineditismo da tese não é tarefa fácil, visto que, diante da imensa produção bibliográfica disponível, é praticamente impossível realizar uma revisão bibliográfica exaustiva. O caráter multidisciplinar do sensoriamento remoto e, em especial, da área de processamento de imagens torna essa tarefa ainda mais árdua. Há de se destacar, no entanto, os aspectos considerados como contribuições científicas inéditas:

1º) a abordagem multivariada baseada em testes de hipóteses para detecção de mudanças no espaço de diferenças de fração;

2º) a associação entre o classificador rígido e uma técnica de análise de agrupamento para inferir sobre o tipo de mudanças;

3º) o uso de regressão logística no espaço de diferenças de fração como um procedimento de classificação suave;

4º) o conjunto de etapas do classificador *fuzzy* para estimação dos graus de pertinência à classe ω_c .

Pode-se destacar, ainda, a utilização de técnicas de classificação rígida, suave e *fuzzy* em um mesmo trabalho, o que, embora não seja completamente inédito, é raro. Por fim, não foi encontrado um conjunto de resultados experimentais tão vasto quanto o exposto nesta tese, em se tratando de detecção de mudanças associada ao MLME.

5.2 TRABALHOS FUTUROS

O tema abordado nesta tese suscita uma grande quantidade de trabalhos futuros. A primeira sugestão está relacionada ao uso de imagens simuladas para a validação de propostas de algoritmos de detecção de mudanças. Partindo do pressuposto de que o conhecimento da verdade terrestre em diferentes datas pode ser uma tarefa difícil de ser operacionalizada, o uso de imagens sintéticas torna-se relevante. A pergunta a ser respondida é: qual faixa de valores de SNR corresponde às situações reais?

Além dessa questão, outras perguntas surgiram durante o período de doutorado, dentre as quais se podem destacar:

- Qual a influência da escolha dos *endmembers* sobre os resultados dos algoritmos propostos?

- Como se dá a transferência do ruído presente nas imagens espectrais para as imagens de fração?

- Como avaliar de maneira menos subjetiva os resultados de classificadores *suave* ou *fuzzy* quando não se dispõe de verdade terrestre em nível de subpixel?

- A classificação suave apresentaria melhores resultados se fossem incluídas informações de vizinhança? Como se operacionalizaria isso?

- Os algoritmos propostos produziram bons resultados sobre imagens oriundas de outros satélites (e.g. CBERS, SPOT e MODIS)?

Como última sugestão, está a programação de uma rotina que insira automaticamente regiões de mudança sobre um par de imagens sintéticas, aplique os algoritmos de detecção de mudanças e calcule as medidas de desempenho sem a necessidade de intervenção do analista. Assim, poder-se-ia realizar centenas de simulações para melhor avaliação do desempenho dos algoritmos.

REFERÊNCIAS

ADAMS, John B.; SABOL, Donald. E.; KAPOs, Valerie; ALMEIDA-FILHO, Raimundo; ROBERTS, Dar A. ; SMITH, Milton. O.; GILLESPIE, Alan R. Classification of multispectral images based on fraction of endmembers: application to land-cover change in the Brazilian Amazon. **Remote Sensing of Environment**, New York, v. 52, p. 137–154, 1995.

ANDERSON, Liana; ARAGAO, Luiz; SHIMABUKURO, Yosio; ALMEIDA, Samuel; HUETE, Alfredo. Fraction images for monitoring intra-annual phenology of different vegetation physiognomies in Amazonia. **International Journal of Remote Sensing**, London, v. 32, n. 2, p. 387–408, 2011.

ALMUTAIRI, Abdullah; WARNER, Timothy A. Change detection accuracy and image properties: a study using simulated data. **Remote Sensing**, Basel, v. 2, n. 6, 2010, p. 1508–1529.

ARAI, Egídio; SHIMABUKURO, Yosio; PEREIRA, Gabriel; VIJAYKUMAR, Nandamudi. A Multi-Resolution Multi-Temporal Technique for Detecting and Mapping Deforestation in the Brazilian Amazon Rainforest. **Remote Sensing**, Basel, v. 3, n. 9, p. 1943-1956, 2011.

BAZI, Yakoub; BRUZZONE, Lorenzo; MELGANI, Farid. An unsupervised approach based n the generalized Gaussian model to automatic change detection in multitemporal SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, Piscataway, v. 43, n. 4, p. 874- 887, 2005.

BITTENCOURT, Hélio R. **Comparação da Discriminação Logística com o Método da Máxima Verossimilhança Gaussiana na classificação de imagens digitais**. 59 f. Dissertação (Mestrado em Sensoriamento Remoto) – CEPsRM, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2001.

BITTENCOURT, Hélio R.; MORAES, Denis A. O.; HAERTEL, Vitor. A Binary Decision Tree Classifier Implementing Logistic Regression as a Feature Selection and Classification Method and its Comparison with Maximum Likelihood. In: International Geoscience and Remote Sensing Symposium, 2007, Barcelona. **Proceedings...** IEEE, 2007. p. 1755–1758.

BITTENCOURT, Hélio R.; HAERTEL, Vitor. Uso de Imagens de Fração na detecção de mudanças. In: XIII Simposio Latinoamericano de Percepción Remota, 2008, **Memorias...** La Habana, Cuba, 2008.

BITTENCOURT, Hélio R.; HAERTEL, Vitor. Detecção de mudanças a partir de imagens de fração: uma abordagem fuzzy empregando o conceito de pixel mistura. In: XIV Simpósio Brasileiro de Sensoriamento Remoto, 2009, Natal. **Anais...** São José dos Campos: INPE, 2009.

BITTENCOURT, Hélio R.; PASINI, Bárbara P. O.; MORAES, Denis A.O.; SANTOS, Bruno D.; HAERTEL, Vitor. Comparative Analysis of two Classifiers Implementing Nominal Logistic Regression. **Revista Brasileira de Biometria**, São Paulo, v. 27, n. 1, p. 115–124, 2009.

BITTENCOURT, Hélio R.; HAERTEL, Vitor. Uma abordagem multivariada para detecção de mudanças a partir de imagens de fração. In: XV Simpósio Brasileiro de Sensoriamento Remoto, 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011.

BOVOLO, Francesca; BRUZZONE, Lorenzo. A Theoretical Framework for Unsupervised Change Detection Based on Change Vector Analysis in the Polar Domain. **IEEE Transactions on Geoscience and Remote Sensing**, Piscataway, v. 45, n. 1, p.218-236, 2007.

BOVOLO, Francesca; BRUZZONE, Lorenzo; MARCHESI, Silvia. A Multiscale Technique for Reducing Registration Noise in Change Detection on Multitemporal VHR images. In: **MultiTemp 2007. Proceedings.....** Leuven: IEEE, 2007.

BOVOLO, Francesca; BRUZZONE, Lorenzo; MARCONCINI, Mattia. A Novel approach to unsupervised change detection based on a semisupervised SVM and a similarity measure. **IEEE Transactions on Geoscience and Remote Sensing**, Piscataway, v. 46, n. 7, p. 2070-2082, 2008.

BRUZZONE, Lorenzo; PRIETO, Diego F. Automatic Analysis of the Difference Image for Unsupervised Change Detection, **IEEE Transaction on Geoscience and Remote Sensing**, Piscataway, v. 38, n. 3, p. 1171-1182, 2000.

BRUZZONE, Lorenzo; SERPICO Sebastiano B. An Iterative Technique for the detection of land-cover transitions in multitemporal remote sensing images, **IEEE Transaction on Geoscience and Remote Sensing**, Piscataway, v. 35, n. 4, p. 858-867, 1997.

BRUZZONE, Lorenzo; COSSU, Roberto. An adaptive approach to reducing registration noise effects in unsupervised change detection. **IEEE Transactions on Geoscience and Remote Sensing**, Piscataway, v. 41, n. 11, part 1, p. 2455 - 2465, 2003.

BOUCHER, Alexandre; SETO, Karen C.; JOURNAL, André G. A Novel Method for Mapping Land Cover Changes: Incorporating Time and Space with Geostatistics. **IEEE Transactions on Geoscience and Remote Sensing**, vol. 44, n.11, Part 2, p. 3427- 3435, 2006.

CANTY, Morton. J. **Image Analysis, Classification and Change Detection in Remote Sensing**. Boca Raton, FL: CRC Press, 2007.

CARVALHO Jr. Osmar. A.; CARVALHO, Ana Paula F.; GUIMARÃES, Renato F.; MENESES, Paulo R.; SHIMABUKURO, Yosio E. Mistura espectral: (I) detecção dos membros finais utilizando a geometria do Simplex. **Espaço & Geografia**. v. 6, n. 1, p. 147-173, 2003.

CASTELLANA, Laura; D'ADDABBO Annarita; PASQUARIELLO, Guido. A composed supervised / unsupervised approach to improve change detection from remote sensing. **Pattern Recognition Letters**, New York, v. 28, n. 4, p. 405-413, 2007.

CELIK, Turgay. Unsupervised Change Detection in Satellite Images Using Principal Component Analysis and *k*-Means Clustering. **IEEE Geoscience and Remote Sensing Letters**, Piscataway, v. 6, n. 4, p. 772-776, 2009a.

CELIK, Turgay. Multiscale Change Detection in Multitemporal Satellite Images. **IEEE Geoscience and Remote Sensing Letters**, Piscataway, v. 6, n. 4, p. 820-824, 2009b.

CELIK, Turgay. Change Detection in satellite images using a genetic algorithm approach. **IEEE Geoscience and Remote Sensing Letters**, Piscataway, v. 7, n. 2, p. 386-390, 2010.

CHENG, Qi; VARSHNEY, Pramod; ARORA, Manoj K. Logistic Regression for feature selection and soft classification of remote sensing data. **IEEE Geoscience and Remote Sensing Letters**, vol. 3, n. 4, p. 491-494, 2006.

CHOU, J. WEGER, R. C. LIGTENBERG, J. M., KUO, K. S., WELCH, R. M., BREEDEN, P. Segmentation of polar scenes using multispectral texture measures and morphological filtering, **International Journal of Remote Sensing**, vol. 15, n. 5, p.1019-1036, 1994.

COCHRANE, Mark A.; SOUZA Jr., Carlos M. Linear mixture model classification of burned forests in the eastern Amazon. **International Journal of Remote Sensing**, v. 19, p. 3433–3440, 1998.

COHEN, Jacob. A coefficient of agreement of nominal scales. **Educational and Psychological Measurement**, vol.20, p. 37–46, 1960.

CONGALTON, Russel G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, vol. 37, p. 35–46, 1991.

COPPIN, Pol, JONCKHEERE, Inge; NACKAERTS, B.; MUYS, Bart; LAMBIN, Eric. Digital change detection methods in ecosystem monitoring: a review, **International Journal of Remote Sensing**, vol. 25, n. 9, p. 1565–1596, 2004.

COULTER, Lloyd L.; STOW, Douglas A. Assessment of the Spatial Co-registration of Multitemporal Imagery from Large Format Digital Cameras in the Context of Detailed Change Detection. **Sensors**. Basel: vol. 8, n. 4, p. 2161-2173, 2008.

DAI, X.; KHORRAM, S. The effects of image misregistration on the accuracy of remotely sensed change detection. **IEEE Transactions on Geoscience and Remote Sensing**, vol 36, n. 5, part 1, p.1566 – 1577, 1998.

DALLA MURA, Mauro; BENEDIKTSSON, Jon. A., BOVOLO, Francesca; BRUZZONE, Lorenzo. An unsupervised technique based on morphological filters for change detection in very high resolution images, **IEEE Geoscience and Remote Sensing Letters**, v. 5, n. 3, p. 433–437, 2008.

DEMPSTER, Arthur P.; LAIRD, Nan M.; RUBIN, Donald B. Maximum Likelihood from incomplete data via the EM algorithm, **Journal of the Royal Statistical Society**, v. 39, n. 1, p. 1–38, 1977.

DI ZENZO, Silvano; BERNSTEIN, Ralph; DEGLORIA, Stephen D.; KOLSKY, Harwood G. Gaussian Maximum Likelihood and Contextual Classification Algorithms for Multicrop Classification, **IEEE Transactions on Geoscience and Remote Sensing**, v. GE-25, n. 6, p. 815 – 824, 1987.

DUDA, Richard O.; HART, Peter E.; STORK, David G. **Pattern Classification**. 2 ed. New York: Wiley, 2001.

FERREIRA, Laerte G., FERREIRA, Nilson C., FERREIRA, Manuel E. Sensoriamento remoto da vegetação: evolução e estado-da-arte. **Acta Scientiarum. Biological Sciences**, vol. 30, n. 4, p. 379–390, 2008.

FERREIRA, Manuel E. **Análise do Modelo Linear de Mistura Espectral na Discriminação de Fitofisionomias do Parque Nacional de Brasília (Bioma Cerrado)**. 2003, 127p. Dissertação (Mestrado em Geologia) – Universidade de Brasília, Brasília, 2003.

FAWCETT, Tom. An Introduction to ROC analysis. **Pattern Recognition Letters**. v. 27, p. 861–874, 2006.

FOODY, Giles M. Status of land cover classification accuracy assessment, **Remote Sensing of Environment**, 80, p. 185–201, 2002.

FRASER, Robert H.; FERNANDES, Richard; LATIFOVIC, Rasim; Multi-temporal burned area mapping using logistic regression analysis and change metrics. In: International Geoscience and Remote Sensing Symposium, 2002, Toronto. **Proceedings...** Piscataway: IEEE, 2002.

GONZALEZ, Rafael C.; WOODS, Richard E; EDDINS, Steven L. **Digital Image Processing using MATLAB**. Upper Saddle River, NJ: Prentice Hall, 2004.

GUSTAFSSON, Fredrik. **Adaptive Filtering and Change Detection**. Chichester: Wiley, 2000.

HAERTEL, Vitor; SHIMABUKURO, Yosio E.; ALMEIDA-FILHO, Raimundo. Fraction Images in Multitemporal Change Detection, **International Journal of Remote Sensing**, v. 25, n. 23, p. 5473–5489, 2004.

HAERTEL, Vitor; SHIMABUKURO, Yosio Edemir. Spectral Linear Mixing Model in Low Spatial Resolution Image Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 43, n. 11, p. 2555–2562, 2005.

HARRIS, R. Contextual classification post-processing of Landsat data using a probabilistic relaxation model. **International Journal of Remote Sensing**, vol. 6, n. 6, p. 847–866, 1985.

HOSMER, David. W. LEMESHOW, Stanley. **Applied Logistic Regression**, 2nd Ed. New York: Wiley, 2000.

IBGE. Instituto Brasileiro de Geografia e Estatística. 2003. **Mapa Geomorfológico**, folha SH.22-X-C. Escala 1:250.000. Acesso em: 20 ago. 2011. Disponível em: ftp://geofp.ibge.gov.br/mapas/tematicos/sistematizacao/geomorfologia/sh22xc_geom.pdf.

JAIN, Anil K.; DUIN Robert P. W.; MAO, Jianchang. Statistical Pattern Recognition: A Review, **IEEE Transactions on Pattern Analysis and Machine Intelligence**, vol. 22, no. 1, p. 04 – 37, 2000.

JAIN, Anil K. Data clustering: 50 years beyond k -means. **Pattern Recognition Letters**. vol. 31, p. 651–666, 2010.

JENSEN, John R. **Introductory Digital Image Processing – A Remote Sensing Perspective**. Prentice Hall: Englewood Cliffs, NJ, 1996.

JIA, Xiuping; RICHARDS, John A. managing the Spectral-Spatial Mix in Context Classification using Markov Random Fields. **IEEE Geoscience and Remote Sensing Letters**, v. 5, n. 2, p. 311–314, 2008.

JOHNSON, Richard A.; WICHERN, Dean W. **Applied Multivariate Statistical Analysis**. 6. ed. Englewood Cliffs: Prentice-Hall, 2007.

JURKOVIC, F. Fuzziness versus Probability again. **Computer Research Repository (CoRR)**: Cornell University Library, 2006. Disponível em: <http://arxiv.org/abs/cs/0312013>. Acesso em: 10 jul. 2011.

KASETKASEM, T.; VARSHNEY, P.K. An image change detection algorithm based on Markov random field models., **IEEE Transactions on Geoscience and Remote Sensing**, Volume 40, Issue 8, Aug. 2002.

KOSKO, B. Fuzziness vs. Probability. **International Journal of General Systems**, v. 17, p. 211–240, 1990.

LANDGREBE, David A. The development of a spectral-spatial classifier for earth observation data. **Pattern Recognition**, vol. 12, p. 165, 1980.

- LILLESTRAND, Robert L. Techniques for change detection. **IEEE Transactions on Computers**, 21, p. 654–659, 1972.
- LU, Dengsheng, BATISTELLA, Mateus, MORAN, Emilio. Multitemporal spectral mixture analysis for Amazonian land–cover change detection, **Canadian Journal of Remote Sensing**, vol. 30, n. 1, p. 87–100, 2004.
- LU, Dengsheng, MAUSEL, P., BRONDÍZIOS, E., MORAN, Emilio. Change Detection Techniques, **International Journal of Remote Sensing**, vol. 25, no. 12, p. 2365–2407, 2003.
- McLACHLAN, Geoffrey. **Discriminant Analysis and Statistical Pattern Recognition**. New York: John Wiley & Sons, 1992.
- MALILA, William A. Change vector analysis: an approach for detecting forest changes with Landsat..In: 6.th Annual Symposium on Machine Processing of Remotely Sensed Data. **Proceedings...** Indiana: Purdue University. p. 326–335, 1980.
- MAS, Jean François. Monitoring land–cover changes: a comparison of change detection techniques. **International Journal of Remote Sensing**, v. 20, n. 1, p. 139–152, 1999.
- MACLEOD, Robb D.; CONGALTON Russel G. A quantitative comparison of change–detection algorithms for monitoring eelgrass from remotely sensed data. **Photogrammetric Engineering and Remote Sensing**. v. 64, n. 3, 1998, p. 207–216.
- MACQUEEN, James B. Some Methods for classification and Analysis of Multivariate Observations. **Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability**. University of California Press, p. 281–297, 1967.
- MELGANI Farid; SERPICO, Sebastiano B. A Markov Random Field Approach to Spatio–Temporal Contextual Image Classification. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 11, p. 2478–2487, 2003.
- MICHALEK, Jeffrey L.; LUCZKOVICH, Joseph J. Multispectral Change Vector Analysis for Monitoring Coastal Marine Environments, **Photogrammetric Engineering and Remote Sensing**, v. 59, p. 381–384, 1993.
- MUCHONEY, Douglas. M.; HAACK, Bary N. Change detection for monitoring forest defoliation. **Photogrammetric Engineering and Remote Sensing**. v. 60, n. 10, p. 1243–1251, 1994.
- NELSON, Ross F. Detecting forest canopy change due to insect activity, using LANDSAT MSS.. **Photogrammetric Engineering and Remote Sensing**, 49, p. 1303–1314, 1983.
- NIELSEN, Allan A., CONRADSEN, Knut, SIMPSON, James J.. Multivariate alteration detection (MAD) and MAF post processing in multi–spectral bi–temporal image data: new approaches to change detection studies. **Remote Sensing of Environment**, vol. 64, n. 1, p.1–19, 1998.
- RADKE, Richard J.; ANDRA, Srinivas; AL–KOFAHI, Omar; ROYSAM, Badrinath. Image Change Detection Algorithms : a systematic survey. **IEEE Transactions on Image Processing**, v. 14, n. 3, 2005.
- RENTERÍA, Alexandre R. **Estimação de Probabilidade Fuzzy a partir de dados imprecisos**. 94 f. Tese (Doutorado em Engenharia Elétrica) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2006.

- RICHARDS, John A. **Remote Sensing Digital Image Analysis: an Introduction**. 2nd ed. Berlin: Springer-Verlag, 1993.
- RIDD, M. K., LIU, J. A Comparison of Four Algorithms for Change Detection in an Urban Environment. **Remote Sensing of Environment**, New York, v. 63, n. 2, p. 95–100, 1998.
- ROBERTS, D.A. et al. Mapping Chaparral in the Santa Monica Mountains using multiple endmember spectral mixture models. **Remote Sensing of Environment**, New York, v. 65, n. 3, p. 267–279, 1998.
- ROGAN, J.; FRANKLIN, J.; ROBERTS, D. A. A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. **Remote Sensing of Environment**, New York, v. 80, p. 143–156, 2002.
- ROSENFELD, Azriel. Automatic detection of changes in reconnaissance data,” **Proceedings... 5th Conv. Mil. Electron.**, p. 492, 1961.
- ROSIN, Paul L. IOANNIDIS, Efsthios. Evaluation of global image thresholding for change detection. **Pattern Recognition Letters**. V. 24, p. 2345–2356, 2003.
- SCHOWENGERDT, Robert A. **Remote Sensing: Models and Methods for Image Processing**. 3ed. Burlington: Academic Press, 2007.
- SCHWEIK, Charles M.; GREEN, Glen M. The use of spectral mixture analysis to study human incentives, actions, and environmental outcomes. **Social Science Computer Review**, Thousand Oaks, v. 17, n. 1, p. 40–63, 1999.
- SHEPARD, J. R. A concept of change detection. **Photogrammetric Engineering and Remote Sensing**, vol. 30, p. 648, July 1964.
- SHIMABUKURO, Yosio E.; SMITH, James A. The least-squares mixing models to generate fraction images from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, n. 1, p. 16–20, 1991.
- SHIMABUKURO, Yosio E.; DUARTE, V.; ARAI, E.; FREITAS, R. M.; LIMA, A.; VALERIANO, D. M.; BROWN, I. F.; MALDONADO, M. L. R. Fraction Images derived from Terra Modis data for mapping burnt areas in Brazilian Amazonia. **International Journal of Remote Sensing**, v. 30, n. 6, p. 1537–1546, 2009.
- SHIMABUKURO, Yosio E. ; BATISTA, G. T.; MELLO, E. M. K. ; MOREIRA, J. C.; DUARTE, V. Using Shade Fraction Image Segmentation to Evaluate Deforestation in Landsat Thematic Mapper Images of the Amazon Region. **International Journal of Remote Sensing**, v. 19, n. 3, p. 535–541, 1998.
- SIMPSON, James J. Image masking using polygon fills and morphological transformations, **Remote Sensing of Environment**, Volume 40, Issue 3, p. 161–183, 1992.
- SINGH, Ashbindu. Digital Change Detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, v. 10, n. 6, p. 989–1003, 1989.
- SOILLE, Pierre; PESARESI, Martino. Advances in mathematical morphology applied to geoscience and remote sensing. **IEEE Transactions on Geoscience and Remote Sensing**, vol. 40, n. 9, p. 2042–2055, 2002.

SOLBERG, Anne H. S.; TAXT, Torfinn; JAIN, Anil K. A Markov Random Field model for classification of multisource satellite imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 34, n. 1, p. 100–113, 1996.

SOUZA Jr. Carlos M.; FIRESTONE, Laurel; SILVA, Luciano M.; ROBERTS, Dar. Mapping Forest Degradation in the Eastern Amazon from SPT04 through spectral mixture models. **Remote Sensing of Environment**, v. 87, n. 4, p. 494–506, 2003.

SPACKMAN, Kent A. Signal detection theory: Valuable tools for evaluating inductive learning. **Proceedings** of the Sixth International Workshop on Machine Learning. San Mateo, CA: Morgan Kaufmann, p. 160–163, 1989.

SWAIN, Philip. H. VARDEMAN, Stephen. B.; TILTON, James C. Contextual classification of multispectral image data, **Pattern Recognition**, vol. 13, p. 429, 1981.

TENG, S.P., CHEN, Y. K., CHENG, K. S., AND LO, H. C. Hypothesis–test–based landcover change detection using multitemporal satellite images – A comparative study, **Advances in Space Research**, v. 41, n. 11, p. 1744–1754, 2008.

THEILER, James. Subpixel Anomalous Change Detection in Remote Sensing Imagery. In: Symposium on Image Analysis and Interpretation, 2008, Santa Fe, NM. **Proceedings...** IEEE Southwest, p. 165–168, 2008.

THEILER, James; SCOVEL, Clint; WOHLBERG, Brendt. FOY, Bernard R. Elliptically contoured distributions for anomalous change detection in hyperspectral imagery. **IEEE Geoscience and Remote Sensing Letters**, vol. 7, no. 2, p. 271–275, 2010.

THERRIEN, Charles. W. **Decision, Estimation and Classification**. New York: Wiley, 1989.

TILTON, James C.; VARDEMAN, Stephen B.; SWAIN, Philip H. Estimation of Context for Statistical Classification of Multispectral . **IEEE Transactions on Image Data Geoscience and Remote Sensing**, vol. GE–20, n. 4, p. 445 – 452, 1982 .

TODT, Viviane. **Detecção em tempo real de desflorestamentos na Amazônia com o uso de dados MODIS/Terra e redes neurais**. 2007, 192p. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007.

TSO, Brandt. MATHER, Paul M. **Classification Methods for Remotely Sensed Data**. 2nd Ed. Boca Raton, FL: CRC Press, 2009.

VERONA, Jane. D.; SHIMABUKURO, Yosio E.; SANTOS, João R. Detecção de mudanças em áreas sob influência da Floresta Nacional do Tapajós-PA, utilizando o modelo linear de mistura espectral. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10., 2001, Foz do Iguaçu– PR. **Anais...** São José dos Campos: INPE, p. 1773–1780, 2001.

WANG, Fangju. Fuzzy supervised classification for remote sensing images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 28, n. 2, p. 194–302, 1990.

WILKINSON, Robert.H. A method of generating functions of several variables using analog diode logic. **IEEE Transactions on Electronic Computers**, vol. 12, p. 112–129, 1963.

YUAN, Ding; ELVIDGE, Chris. NALC Land Cover Change Detection Pilot Study: Washington D.C. Area Experiments. **Remote Sensing of Environment**, v. 66, n. 2, p. 166–178, 1998.

ZADEH, Lotfi A Fuzzy sets, **Information and Control**, vol. 8, n. 3, p. 338–353, 1965.

ZADEH, Lotfi. A Fuzzy algorithms. **Information and Control**, vol. 12, n. 2, p. 94–102, 1968.

ZANOTTA, Daniel C. **Uma abordagem fuzzy na detecção automática de mudanças usando imagens de fração e informações de contexto espacial**. 2010. Dissertação (Mestrado em Sensoriamento Remoto) – Centro de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, 2010.

ZITOVA, Barbara.; FLUSSER, Jan. Image registration methods: a survey. **Image and Vision Computing**, 21, p. 977–1000, 2003.

ZWEIG, Mark H.; CAMPBELL, Gregory. Receiver–operating characteristic (ROC) plots: a fundamental evaluation tool in clinical medicine". **Clinical Chemistry**. v. 39, n. 4, p. 561–577, 1993.

APÊNDICE A

FUNÇÃO GAMA¹

A Função Gama (Γ) pode ser considerada como uma extensão do fatorial para o domínio dos números complexos, excetuando os números inteiros negativos, sendo definida por meio da integral imprópria:

$$\text{Gama}(x) = \Gamma(x) = \int_0^{\infty} t^{x-1} e^{-t} dt$$

Ela apresenta algumas propriedades peculiares, como, por exemplo:

$$\Gamma(x+1) = x!$$

$$\Gamma(x+1) = x \Gamma(x)$$

$$\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$$

Graficamente a função Gama tem um comportamento estranho, especialmente para os números negativos devido aos pontos de descontinuidade. A Figura 1 mostra o gráfico da função Gama apenas para os números positivos que são de maior interesse.

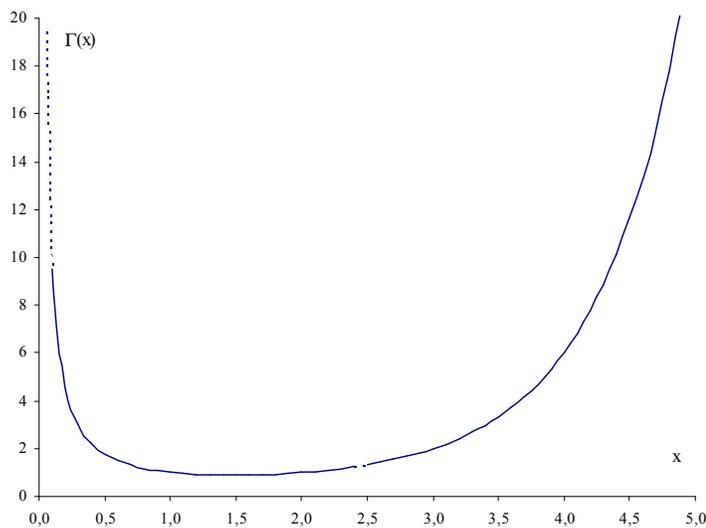


Figura A.1 – Gráfico da função Gama no domínio dos números reais positivos

¹ Texto adaptado de :
VIALI, Lorí. ; BITTENCOURT, Hélio R. . As Distribuições de Probabilidade T, F e Qui-Quadrado: teoria e prática com o uso da planilha.
In: IX Encontro Nacional de Educação Matemática, 2007, Belo Horizonte, **Anais do IX ENEM**, Belo Horizonte: SBEM, 2007.

APÊNDICE B.2

CÓDIGO FONTE PARA O CLASSIFICADOR RÍGIDO

(Autor: Hélio Radke Bittencourt)

```
function [CM, CM4, CM8, CMF]=Rigido(img_t1,img_t2,th,clu)

%Para rodar este programa, digite a seguinte linha de comando
% [CM, CM4, CM8, CMF]=Rigido(img_t1,img_t2,th,clu);
% onde img_t1 e img_t2 são imagens de fração em formato RASTER em t1 e t2
% CM = mapa de mudanças binário sem filtragem (formato RXC)
% CM4 = mapa de mudanças binário com filtragem B4 (formato RXC)
% CM8 = mapa de mudanças binário com filtragem B8 (formato RXC)
% CMF = mapa temático sobre a imagem sem filtro (formato RXC)
tic;

if size(img_t1,2)~=size(img_t2,2)||size(img_t1,1)~=size(img_t2,1)||th>100
    disp('Dimensões incompatíveis ou threshold > 100')
end
    % Imagem de diferenças
    dim=size(img_t1,2);
    diff= img_t2(:,1:dim-1)-img_t1(:,1:dim-1);
    diff3=img_t2(:,1:dim)-img_t1(:,1:dim);
    n=size(diff,1);
    nl=sqrt(size(diff,1));
    nc=sqrt(size(diff,1));

    % Teste de Hipóteses
    S=cov(diff);
    SINV=inv(S);
    qui=diff(:,1).*(diff(:,1)*SINV(1,1)+diff(:,2)*SINV(1,2))+diff(:,2).*(diff(:,1)*SINV(1,2)+diff(:,2)*SINV(2,2));
    quith=[qui>chi2inv(th/100,2)];

    % Filtragem morfológica
    CM=seeimg(quith,nl,nc);
    tematica_op4=imopen(CM,[0 1 0;1 1 1; 0 1 0]);
    CM4=imclose(tematica_op4,[0 1 0;1 1 1; 0 1 0]);
    ponte4=CM4';
    t4=ponte4(:);

    tematica_op8=imopen(CM,[1 1 1;1 1 1; 1 1 1]);
    CM8=imclose(tematica_op8,[1 1 1;1 1 1; 1 1 1]);
    ponte8=CM8';
    t8=ponte8(:);

figure(1)
subplot(1,3,1),imagesc(CM,[0 1]), colormap(gray);title('Qui-quadrado'), axis off
subplot(1,3,2),imagesc(CM4,[0 1]), colormap(gray);title('Filtro Morfológico B4'), axis off
subplot(1,3,3),imagesc(CM8,[0 1]), colormap(gray);title('Filtro Morfológico B8'), axis off

    % Análise de agrupamento
    [y,i]=sort(quith,'descend');
    dif_qui=diff3([i(1:sum(quith))],:);
    [IDX, C] = KMEANS(dif_qui, clu);
    quith_clu=int8(quith);
    for ii=1 : sum(quith)
        IDX(ii);
        quith_clu(i(ii))=IDX(ii);
    end

    CMF=seeimg(quith_clu,nl,nc);
    figure(2)
    imagesc(CMF,[0 max(IDX)]), colormap(jet);title('Clusters'), axis off, colorbar

    disp('Centróides'), C
toc
```

APÊNDICE B.3

CÓDIGO FONTE PARA O CLASSIFICADOR SUAVE

(Autor: Hélio Radke Bittencourt)

```
function [CMP]=Suave(img_t1,img_t2,th,amostra)
tic;
%Para rodar este programa, digite a seguinte linha de comando
%   [CMP]=Suave(img_t1,img_t2,th,amostra);
%   onde img_t1 e img_t2 são imagens de fração em formato RASTER em t1 e t2
%   th é o valor do threshold entre 0 e 100
%   amostra é o percentual da imagem utilizado para estimação
%   CMP = mapa de probabilidades (formato RXC)

if size(img_t1,2)~=size(img_t2,2)||size(img_t1,1)~=size(img_t2,1)||th>100||amostra>100
    disp('Dimensões incompatíveis,threshold > 100 ou amostra')
end
dim=size(img_t1,2);
diff= img_t2(:,1:dim-1)-img_t1(:,1:dim-1);
diff3=img_t2(:,1:dim)-img_t1(:,1:dim);
n=size(diff,1);
nl=sqrt(size(diff,1));
nc=sqrt(size(diff,1));
S=cov(diff);
SINV=inv(S);
qui=diff(:,1).*(diff(:,1)*SINV(1,1)+diff(:,2)*SINV(1,2))+diff(:,2).*(diff(:,1)*SINV(1,2)+diff(
(:,2)*SINV(2,2));
quith=[qui>chi2inv(th/100,2)];

tematica=seeimg(quith,nl,nc);
    tematica_op4=imopen(tematica,[0 1 0;1 1 1; 0 1 0]);
    tematica_cl4=imclose(tematica_op4,[0 1 0;1 1 1; 0 1 0]);
    ponte4=tematica_cl4';
    t4=ponte4(:);
aleat=round(rand(size(diff,1)*(amostra/100),1)*(size(diff,1)-1))+1;
diffs=diff([aleat],:);
quiths=t4([aleat]);
warning off
disp ('Rodando a Regressão Logística...');
B = MNRFIT(abs(diffs),(1-quiths)+1);
Bval = MNRVAL(B,abs(diff));
CMP=seeimg(Bval(:,1),nl,nc);
figure (1)
    imagesc(CMP,[0 1]), colormap(gray), colorbar;title('Mapa de probabilidades'), axis off
toc
end
```

APÊNDICE B.4

CÓDIGO FONTE PARA O CLASSIFICADOR FUZZY

(Autor: Hélio Radke Bittencourt)

```
function [w4 w8]=CMfuzzy(img_t1,img_t2)
tic

if size(img_t1,2)~=size(img_t2,2)||size(img_t1,1)~=size(img_t2,1)
    disp('Dimensões incompatíveis, ou threshold > 100')
else
    dim=size(img_t1,2);
    diff= img_t2(:,1:dim-1)-img_t1(:,1:dim-1);
    n=size(diff,1);
    nl=sqrt(size(diff,1));
    nc=sqrt(size(diff,1));
    S=cov(diff);
    SINV=inv(S);
    qui=diff(:,1).*(diff(:,1)*SINV(1,1)+diff(:,2)*SINV(1,2))+
        diff(:,2).*(diff(:,1)*SINV(1,2)+diff(:,2)*SINV(2,2));
    quiprob=chi2cdf(qui,2);
    matriz_w=seeimg(quiprob,nl,nc);
    w4=zeros(nl,nc);
    w8=zeros(nl,nc);

    % Calculo dos graus de pertinência

    disp('Calculando os graus de pertinência...')

    for row = 2 : nl - 1
        row
        for col = 2 : nc -1
            w4(row,col)=matriz_w(row,col-1)*matriz_w(row,col)*matriz_w(row,col+1)*
                matriz_w(row-1,col)*matriz_w(row+1,col);

            w8(row,col)=matriz_w(row-1,col-1)*matriz_w(row-1,col)*matriz_w(row-1,col+1)*
                matriz_w(row,col-1)*matriz_w(row,col)*matriz_w(row,col+1)*
                matriz_w(row+1,col-1)*matriz_w(row+1,col)*
                matriz_w(row+1,col+1);
        end
    end

    disp('Calculo terminado...')

    figure(1)
        subplot (1,2,1),imagesc(w4(:,:),[0 1]),colormap(gray), title('w4'), axis off
        subplot (1,2,2),imagesc(w8(:,:),[0 1]),colormap(gray), title('w8'), axis off

    w4t=w4';
    w8t=w8';
    w4lista=w4t(:);
    w8lista=w8t(:);

    figure(2)
        subplot (1,2,1),hist(w4lista,40), title('w4')
        subplot (1,2,2),hist(w8lista,40), title('w8')

end
toc
end
```

APÊNDICE C

ANÁLISE ESTATÍSTICA DESCRITIVA DAS REFERÊNCIAS BIBLIOGRÁFICAS

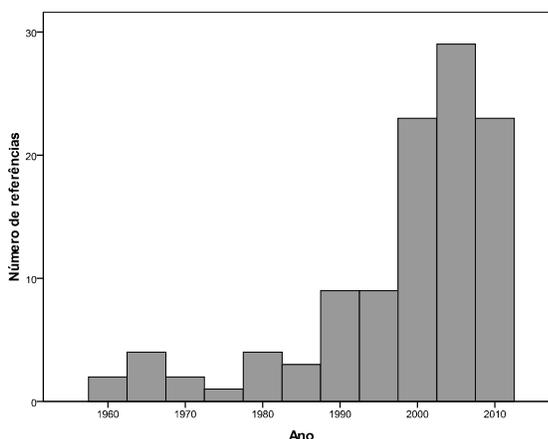


Figura C.1 – Histograma do ano das publicações referenciadas

Tabela C.1 – Tipos de publicações referenciadas

<i>Tipo</i>	<i>Referências</i>	<i>%</i>
Periódico	76	71,0%
Livro	12	11,2%
Congresso	12	11,2%
Dissertação ou Tese	5	4,7%
Outro	2	1,9%
Total	107	100,0%

Tabela C.2 – Periódicos referenciados

<i>Nome da publicação</i>	<i>Referências</i>	<i>%</i>
IEEE Transactions on Geoscience and Remote Sensing	16	21,1%
International Journal of Remote Sensing	11	14,5%
Remote Sensing of Environment	10	13,2%
IEEE Geoscience and Remote Sensing Letters	7	9,2%
Photogrammetric Engineering and Remote Sensing	5	6,6%
Pattern Recognition Letters	4	5,3%
Information and Control	2	2,6%
Pattern Recognition	2	2,6%
Remote Sensing	2	2,6%
Acta Scientiarum (Biological Sciences), Advances in Space Research, Clinical Chemistry, Educational and Psychological Measurement, Espaço & Geografia, IEEE Transactions on Computers, IEEE Transactions on Electronic Computers, IEEE Transactions on Image Data, IEEE Transactions on Image Processing, IEEE Transactions on Pattern Analysis and Machine Intelligence, Image and Vision Computing, International Journal of General Systems, Journal of the Royal Statistical Society, Revista Brasileira de Biometria, Sensors, Social Science Computer Review	17 (1 citação cada)	22,4%
Total	76	100,0%