

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE PESQUISAS HIDRÁULICAS
CURSO DE PÓS-GRADUAÇÃO EM
RECURSOS HÍDRICOS E SANEAMENTO

EXPLORAÇÃO DE ATRIBUTOS DE CONTEXTO EM IMAGENS DIGITAIS NO
ESTUDO DA COBERTURA VEGETAL EM BACIAS HIDROGRÁFICAS

Autor : Eng. Civil Jorge Antonio Silva Centeno
Orientador : Prof. Dr. Vitor Haertel

Dissertação apresentada como requisito para a obtenção do grau de Mestre em Engenharia Civil, área de concentração Recursos Hídricos e Saneamento no Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul.

Porto Alegre, setembro de 1991

AGRADECIMENTOS

Ao término deste trabalho o autor deseja agradecer às pessoas que o fizeram possível:

Ao professor Vitor Haertel da UFRGS, por ter contribuído com seu conhecimento e experiência durante o desenvolvimento do trabalho e principalmente pela amizade brindada a todo momento;

Aos professores Jandyra Fachel, Carlos Tucci e Antonio E. Lanna pelas sugestões e contribuição técnico-científica com que auxiliaram o trabalho;

A sua noiva Regina, a seus pais Julio e Nancy, irmãs Jenny e Oscar e a toda família, pelo carinho e confiança;

Aos colegas e amigos José Carlos Nunes, André B. Mendes e Alfonso Risso e suas respectivas famílias, pelos momentos inesquecíveis compartilhados durante estes anos;

A todos os funcionários e corpo docente do CEPSRM e do IPH pelo apoio, amizade e colaboração;

E finalmente às entidades que contribuíram para a sua conclusão:

Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES);

Centro Estadual de Pesquisas em Sensoriamento e Meteorologia (CEPSRM);

e Instituto de Pesquisas Hidráulicas (IPH/UFRGS).

Resumo

O conhecimento atualizado da cobertura vegetal de bacias hidrográficas é importante para o estudo de processos hidrológicos como por exemplo os de erosão, infiltração ou escoamento superficial. Uma forma de estimar esta informação é através de técnicas de sensoriamento remoto, especialmente em países em desenvolvimento, onde a cobertura de aerofotogrametria não está regularmente disponível.

O presente trabalho apresenta o uso dos atributos de contexto como meio de melhorar a precisão da classificação da Máxima Verossimilhança Gaussiana de imagens usadas em sensoriamento remoto. Para isto, os algoritmos de relaxação fuzzy e probabilística são testados. Este tipo de processo implementa a informação contextual mediante coeficientes de compatibilidade espacial entre classes. De maneira geral, os processos de relaxação iniciam-se com uma primeira estimativa da probabilidade que associa cada pixel a cada uma das classes consideradas, a qual é posteriormente corrigida iterativamente utilizando os coeficientes de compatibilidade. Paralelamente, um método alternativo é proposto, no qual as probabilidades são submetidas a um processo de filtragem espacial para, a seguir, utilizar a relaxação probabilística.

Testes com imagens sintéticas e reais, comprovam que a precisão da classificação pode ser aumentada utilizando os atributos de contexto. Os mapas temáticos obtidos por estas metodologias são mais homogêneos e neles pixels de mesma classe se apresentam agrupados espacialmente, tornando a imagem mais adequada para análise, facilitando assim a caracterização da cobertura vegetal da bacia.

Abstract

Updated knowledge of Land-cover in watersheds plays an important role in the study of hydrological processes as soil erosion, infiltration or runoff. Remote sensing techniques are an invaluable tool for this purpose, specially in third world countries, where regular air-photograph coverage is not available.

This study applies contextual attributes to improve the accuracy of the Gaussian Maximum Likelihood classification of remote sensing images. Therefore, fuzzy and probabilistic relaxation are tested. Such iterative processes implement contextual information using coefficients that represent spatial compatibility between classes. Relaxation processes starts making an initial estimate of the probabilities that relate each pixel to the classes considered in the classification. This estimates are then iteratively updated

using the compatibility coefficients. An alternative procedure is introduced, in which probabilities are first filtered using a low pass filter and then the probabilistic relaxation is used.

Tests with synthetic images and real LANDSAT scenes confirm that the accuracy of the classification can be incremented using contextual information. The resulting thematic maps are more homogeneous and pixels of the same class form groups, making the image more adequate to analysis and making it easier to characterize land-cover of the basins.

S U M A R I O

	Pag.
LISTA DE SIMBOLOS UTILIZADOS	
LISTA DE FIGURAS E TABELAS	
I. INTRODUÇÃO.....	1
II. REVISÃO BIBLIOGRAFICA.....	5
2.1. Sensoriamento Remoto.....	5
2.2. O processo de aquisição de informações.....	6
2.3. Características espectrais de alguns alvos e sistemas sensores	10
2.4. Imagens Digitais	14
2.4.1. Atributos das imagens.....	15
2.4.2. Características das imagens digitais.....	17
2.4.3. Utilização de imagens digitais.	20
2.4.3.1. Processamento de imagens digitais.....	20
2.4.3.2. Classificação de imagens digitais.....	20
2.5. Revisão de experiências no uso de atributos de contexto no processo de classificação.....	25
III. METODOLOGIA	37
3.1. A classificação pela Máxima Verossimilhança multiespectral.....	37
3.2. A implementação do conceito de contexto em uma imagem digital.....	42
3.3. Processos de relaxação.....	44
3.3.1. O valor da probabilidade inicial.....	46
3.3.2. O valor da probabilidade inicial associado à classe "fundo".....	47
3.3.3. Processo de relaxação probabilística.....	51
3.3.4. O coeficiente de compatibilidade de contexto.....	54
3.3.5. Processo de relaxação fuzzy.....	57

3.3.6. Processo de relaxação fuzzy modificado com a média local.....	62
3.3.7. Processo combinado de filtragem espacial e relaxação probabilística.....	64
3.4. Imagem Sintética.....	66
3.5. Critérios de convergência e avaliação da precisão.....	71
IV. EXPERIMENTOS.....	74
4.1. Descrição das imagens.....	74
4.1.1. Imagem sintética.....	74
4.1.1.1. Entradas do programa SINTET para geração de imagens sintéticas.....	75
4.1.1.2. Imagens geradas.....	77
4.1.2. Imagens reais.....	79
4.2. Testes.....	87
4.2.1. Testes com imagens sintéticas.....	87
4.2.1.1. Classificação usando unicamente atributos espectrais.....	88
4.2.1.2. Relaxação probabilística.....	90
4.2.1.3. Relaxação fuzzy	90
4.2.1.4. Relaxação fuzzy com introdução da média ...	91
4.2.1.5. Processo combinado de filtragem espacial e relaxação probabilística	91
4.2.1.6. Processo combinado de relaxação probabilística e fuzzy.....	92
4.2.2. Testes com imagens reais.....	93
4.2.2.1. Classificação usando unicamente atributos espectrais.....	93
4.2.2.2. Relaxação Probabilística.....	96
4.2.2.3. Processo combinado de filtragem e Relaxação Probabilística	96
V RESULTADOS.....	98
5.1. Imagens sintéticas.....	98

5.1.1. Classificação usando unicamente atributos espectrais.....	98
5.1.2. Relaxação Probabilística.....	100
5.1.3. Relaxação Fuzzy	104
5.1.4. Relaxação fuzzy modificado com a média local.....	107
5.1.5. Processo combinado de filtragem e relaxação probabilística	108
5.1.5.1 Teste de diferentes filtros.....	108
5.1.5.2. Aplicação do processo combinado de filtragem e relaxação probabilística.....	109
5.1.6. Processo combinado de 4 relaxações probabilísticas e 4 fuzzy.....	111
5.2. Imagens reais.....	112
5.2.1. Classificação usando unicamente atributos espectrais.....	112
5.2.2 Relaxação probabilística	114
5.2.3. Processo combinado de filtragem e relaxação probabilística	116
VI. CONCLUSÕES E RECOMENDAÇÕES.....	119
VII. BIBLIOGRAFIA.....	126
APÊNDICE "A" - TABELAS E FIGURAS DOS RESULTADOS	

LISTA DE SIMBOLOS UTILIZADOS

- λ = comprimento de onda
- J = número de colunas de uma imagem digital
- I = número de linhas de uma imagem digital
- (i_1, i_2) = coordenadas de um ponto na imagem ($0 \leq i_1 \leq I-1$ e $0 \leq i_2 \leq J-1$)
- n = número de indivíduos na população
- p = número de bandas que compõem a imagem multiespectral (dimensionalidade de \underline{x})
- X = conjunto dos pixels que formam a imagem
- \underline{x}_i = $(x_1, x_2, x_3, \dots, x_p)'$ = vetor de estado do pixel na posição "i" da imagem
- \underline{x}' = vetor transposto de \underline{x}
- i = identifica o pixel central na janela 3x3
- j = indice que identifica qualquer pixel dentro da vizinhança estabelecida.
- m = Número de classes possíveis presentes na cena.
- Ω = Conjunto das classes possíveis presentes na cena
- ω_h = classe "h" presente na cena
- h, k = indice da classe ω $h, k = 0, 1, 2, 3, 4, \dots, m$
- σ = variância da população
- μ = média da população
- \underline{m}_h = vetor de médias da classe ω_h
- Σ_h = matriz de covariância da classe ω_h
- $P(\omega_h)$ = distribuição "a priori" da classe ω_h
- $P(\omega_h | \underline{x})$ = probabilidade "a posteriori" da classe ω_h acontecer, dado \underline{x}
- $p(\underline{x} | \omega_h)$ = probabilidade condicional de \underline{x} dada a classe ω_h
- $P(\omega_h)$ = probabilidade "a priori" associada à classe ω_h
- $p(\underline{x})$ = função densidade de probabilidade incondicional de \underline{x} para a classe ω_h
- $D_h(\underline{x})$ = função discriminante de \underline{x} associada à classe ω_h para a classificação pelo método da Máxima Verossimilhança.
- $F(\cdot)$ = função de contexto
- t = iteração no processo de relaxação
- $q_i^t(\omega)$ = contribuição da vizinhança do pixel "i" na iteração t no

processo de relaxação

$p_i^t(\omega_h)$ = probabilidade de x_i associada à classe ω_h na iteração t do processo de relaxação

T^2 = estatística de Hotelling.

S = estimativa da matriz variância covariância

F = estatística de Fisher com $(n, n-p)$ graus de liberdade

α = nível de significância

$r_j(h, k)$ = coeficiente de compatibilidade entre a ocorrência da classe h na posição i e da classe k na posição j

d_{ij} = coeficiente que representa a influencia da posição j no valor de $q_i(h)$.

$NC(j, h, k)$ = número de vezes que um pixel (não localizado nas bordas da imagem) é classificado como h e, ao mesmo tempo, seu vizinho j é classificado como k .

$NTOTAL$ = número total de pixels presentes na área a ser classificada.

$RC(t)$ = taxa média de variação da iteração

N = número de pixels classificados na iteração t .

$H(t)$ = entropia da imagem após t iterações.

\wedge, \vee = operadores fuzzy mínimo e máximo respectivamente

$a \frown b, a \vee b$ = operadores fuzzy modificados, com limiar τ

$\delta(\)$ = função delta de Kroneker

$f(K)$ = função de pertinência fuzzy

$\mathcal{F}(d)$ = conjunto dos valores possíveis para a função de pertinência fuzzy

$\ell_1, \ell_2, \dots, \ell_p$ = autovalores

e_{ℓ_1} = autovetor associado ao autovalor ℓ_1

\underline{B}^{-1} = matriz inversada matriz \underline{B}

\underline{I} = matriz identidade

LISTA DE FIGURAS

FIGURA 2.1.- O processo de aquisição de informações com técnicas de sensoriamento remoto.....	7
FIGURA 2.2.- Efeitos atmosféricos em relação ao comprimento de onda. Energia no topo da atmosfera e na superfície da terra.....	9
FIGURA 2.3.- Resposta espectral em função do comprimento de onda para Solo, Vegetação e Água.....	9
FIGURA 2.4.- Exemplos de implementação da informação contextual em imagens digitais.....	16
FIGURA 3.1.- Exemplos de janelas utilizadas em imagens digitais.....	43
FIGURA 3.2.- Janela e convenção adotada no presente estudo.....	46
FIGURA 3.3.- O valor da probabilidade inicial associada à classe "fundo".....	50
FIGURA 4.1.a,b,c.- Representação gráfica da distribuição espectral das classes geradas para a imagem sintética.....	80
FIGURA 4.2.- Distribuição espacial das classes nas imagens sintéticas SIC e SIE geradas.....	81
FIGURA 4.3- Fotografia aérea da area de estudo localizada na bacia do rio Potiribú.....	83
FIGURA 4.4.- Fotografia de uma região da imagem utilizada como imagem de estudo	84
FIGURA 4.5.- Fotografia de uma região da imagem utilizada como area teste Potiribú 1	85
FIGURA 4.6.- Fotografia de uma região da imagem utilizada como area teste Potiribú 2	86
FIGURA 4.7.- Filtros utilizados no processo de filtragem espacial das bandas de funções discriminantes normalizadas...	91
FIGURA 5.1.- Exemplo de valores das probabilidades normalizadas dentro de uma vizinhança definida em duas classes.....	104

LISTA DE TABELAS

TABELA 2.1.- Características dos sistemas sensores usados no estudo dos recursos naturais	15
TABELA 3.2.- Efeito do coeficiente de compatibilidade no valor da probabilidade do pixel central no processo contextual.....	53
TABELA 4.1.- Parâmetros estatísticos das classes utilizadas na classificação da imagem SIC.....	88
TABELA 4.2.- Parâmetros estatísticos das classes utilizadas na classificação da imagem SIC.....	88

I INTRODUÇÃO

Sensoriamento remoto pode ser definido como a ciência e a técnica de obtenção de dados a respeito de objetos a distância, isto é, sem necessidade de entrar em contato direto com os mesmos. Esses objetos de interesse, genericamente designados por "alvos" são geralmente corpos de água, tipos de vegetação, solos, rochas e outros.

Inicialmente, essa técnica restringiu-se à interpretação visual de fotografias aéreas. Com o surgimento da era espacial na década de 70, os progressos realizados no desenvolvimento de sensores eletrônicos e na disponibilidade de computadores digitais, sensoriamento remoto adquiriu uma nova dimensão. A disponibilidade de imagens tomadas simultaneamente em diversas faixas do espectro eletromagnético e de uma maneira repetitiva aumentou muito a quantidade e confiabilidade dos dados assim obtidos. Ainda mais, sendo disponíveis em formato digital, as imagens tornaram-se suscetíveis de serem processadas e classificadas em computadores, segundo algoritmos diversos, criando novas possibilidades de utilização prática de sensoriamento remoto bem como abrindo novas áreas para pesquisa científica.

Hoje, uma parcela significativa do estudo dos recursos naturais faz uso de imagens de satélite. Mediante o sensoriamento remoto é possível acompanhar fenômenos que se desenvolvem em grandes áreas sobre a superfície da Terra. Um exemplo é o estudo dos efeitos da cobertura superficial em bacias hidrográficas nos processos de erosão e escoamento superficial.

Durante os últimos anos cresceram as aplicações de modelos implementados em computador destinados a simular a hidrologia de áreas urbanas e rurais. Tais modelos são por demais variados na sua estrutura e grau de complexidade, mas todos eles necessitam informações sobre o estado da bacia, que são traduzidas em parâmetros hidrológicos típicos do modelo. O conjunto de informações inclui dados a respeito da topografia do terreno, geomorfologia, capacidade de infiltração e tipo

de cobertura vegetal, entre outros, alguns dos quais são relacionados a processos dinâmicos da bacia. As dificuldades encontradas na estimativa destes parâmetros obrigam, as vezes, a adotar aproximações baseadas na experiência do profissional ou na flexibilidade do modelo utilizado.

A procura da melhor compreensão dos fenômenos hidrológicos que se realizam na superfície da bacia hidrográfica exige o conhecimento do tipo de cobertura superficial da mesma. Tal conhecimento possibilita uma adequada caracterização da área de estudo, o que facilita a análise dos problemas que a podem afetar e a proposta de soluções. O tipo e a distribuição da cobertura do solo em bacias hidrográficas têm grande influência na sua resposta hidrológica. Diferentes tipos de cobertura têm efeitos dramaticamente diferentes nas características de infiltração e escoamento dos solos que cobrem a bacia. O fator cobertura do solo ganha particular importância na determinação dos volumes e picos de escoamento, assim como nos processos de erosão. Conseqüentemente os hidrólogos têm a necessidade de contar com informação atualizada e de fácil obtenção sobre a cobertura da superfície da bacia hidrográfica em diferentes escalas.

Nesse particular, as técnicas de sensoriamento remoto oferecem um meio rápido, eficiente e de baixo custo no processo de obtenção desses dados. Os métodos de classificação de imagens digitais multiespectrais por computador atualmente disponíveis, em sua grande maioria fazem uso dos atributos espectrais da imagem. Esse fato deve-se basicamente à facilidade com que esses atributos, que medem a radiância ou refletância do alvo nas diversas bandas espectrais, podem ser quantificados numericamente. Outros atributos (atributos espaciais, atributos de contexto) por serem de tratamento mais complexo não foram ainda plenamente explorados nos processos de classificação por computador. O desenvolvimento de algoritmos, implementando atributos espaciais e/ou de contexto para fins de classificação de imagens digitais constitui-se hoje em um tópico de interesse, alvo da atenção de diversos pesquisadores. O objetivo desta dissertação consiste no desenvolvimento de uma metodologia que utiliza atributos de contexto

no processo de classificação de imagens digitais por computador. Procura-se desta forma aumentar a exatidão desse processo, em comparação aos métodos que utilizam exclusivamente atributos espectrais. Uma ênfase particular é dada ao problema do levantamento da cobertura vegetal do solo em bacias hidrográficas.

Os benefícios mais evidentes desta pesquisa encontram-se na elaboração de uma metodologia de fundamental importância para :

- Otimizar os processos de classificação por computador de imagens digitais em sensoriamento remoto, através da exploração dos atributos de contexto das mesmas.
- Permitir, mediante os resultados obtidos, acompanhar as variações naturais, ou devidas à ação antrópica, da cobertura superficial da bacia hidrográfica com uma exatidão maior que a fornecida pelos métodos convencionais.
- Aprimorar as funções do sistema de tratamento de imagens disponível no CEPSRM/IPH mediante a introdução de algoritmos adicionais para classificação de imagens digitais.
- Auxiliar os trabalhos de estimativa de parâmetros hidrológicos da bacia hidrográfica através do aprimoramento dos métodos de classificação de imagens digitais.

Para sua melhor compreensão o presente trabalho foi organizado e dividido da seguinte maneira: O capítulo 2 compreende duas partes. A primeira aborda os processos envolvidos na coleta de dados por meio de técnicas de sensoriamento remoto, bem como o uso destes sob forma de imagens digitais. Sua inclusão pretende servir de ajuda ao leitor não familiarizado com os processos de coleta e processamento da informação em sensoriamento remoto. A segunda parte faz uma revisão bibliográfica das diferentes formas de abordar o problema da exploração dos atributos de contexto em imagens digitais, tentando possibilitar uma visão geral das necessidades e possíveis vantagens que podem ser obtidas com estes métodos. O capítulo 3 apresenta a fundamentação teórica necessária para a elaboração da metodologia de exploração dos atributos de contexto aqui utilizada. No capítulo 4 são apresentados os resultados

das experiências realizadas tanto com imagens sintéticas como com imagens reais de uma bacia hidrográfica. No capítulo 5 os resultados obtidos são discutidos e são apresentadas conclusões e algumas recomendações que podem auxiliar estudos similares futuros.

II REVISÃO BIBLIOGRÁFICA

Introdução

O processo de aquisição de informações a respeito da cobertura superficial de bacias hidrográficas, por meios diferentes ao sensoriamento remoto, geralmente são onerosos, tanto em custos como em tempo. Para que as campanhas no campo possibilitem um adequada descrição da bacia, o seu número deve ser suficiente para cobrir representativamente toda a área, multiplicando os custos em função do número de pontos de amostragem. A alternativa apresentada pelo uso de imagens de satélite se mostra vantajosa neste sentido, mas deve-se considerar as características das mesmas para avaliar seus resultados e poder compará-los com outras técnicas de coleta de informação. Frequentemente a perda de detalhe é compensada pelo ganho na área coberta e pela economia obtida em custo e tempo na execução da tarefa.

Stafford [1975] utilizou a fotografia aérea para determinar mudanças na cobertura superficial em bacias hidrográficas e concluiu que ela é uma excelente ferramenta, quando existe uma cobertura aerofotogramétrica periódica da área. Também comenta que a fotografia aérea é vantajosa na determinação da área ocupada por cada uma das classes de uso do solo e que outras técnicas de sensoriamento remoto deveriam ser utilizadas em estudos similares dentro das limitações próprias de cada sensor.

2.1. Sensoriamento Remoto

Nesta dissertação, é utilizada a definição mais comumente aceita de sensoriamento remoto como sendo a ciência e a técnica que trata da aquisição de informação sobre um objeto a partir de medidas feitas a distância do objeto, isto é, sem que haja contato físico com o mesmo. (Landgrebe 1980). Esta é uma definição geral que frequentemente conduz a polêmicas quanto à distância a partir da qual as medições passam a ser consideradas sensoriamento remoto ou quanto à natureza dos

fenômenos medidos. Faz-se então necessário esclarecer que o termo sensoriamento remoto é atualmente restrito aos sistemas e técnicas envolvidas na utilização da energia eletromagnética refletida e/ou emitida pelo objeto de interesse, incluindo-se as frequências relativas à região visível, ao infravermelho (refletido e emitido) e radar, medidas a partir de aeronaves ou satélites, e utilizados com o objetivo de estudar o ambiente mediante o registro e a análise da interação entre a energia eletromagnética e os elementos que compõem a cobertura da superfície da Terra.

Devido à altitude da órbita dos satélites, as imagens obtidas por sensoriamento remoto estão geralmente em escalas menores às disponíveis por outros meios, possibilitando a cobertura de grandes áreas. Isto facilita a observação e o estudo da cobertura superficial ao longo de grandes áreas e oferece uma alternativa que foge das observações pontuais, comumente feitas nos métodos convencionais. A grande vantagem deste fato é que levantamentos que antes eram feitos de forma pontual, e que para cobrir grandes áreas resultavam muito caros, com as novas técnicas de sensoriamento remoto podem ser feitos com maior facilidade e menores investimentos em capital e trabalho.

2.2. O Processo de Aquisição de Informações

Existe uma variedade de processos envolvidos no sensoriamento remoto como técnica de aquisição de informações (figura 2.1). Alguns deles podem ser englobados num conjunto denominado coleta de dados, outros estão incluídos dentro da análise e interpretação destes. Estudar-se-á primeiro a coleta de dados, tentando, de uma maneira simplificada, ilustrar a aquisição de informação através de sensores colocados a bordo de satélites.

O processo se origina na emissão de radiação eletromagnética por parte de uma fonte de energia. A fonte natural geralmente utilizada para esta finalidade é o Sol. A radiação eletromagnética proveniente do Sol se propaga através do espaço em direção à Terra. No seu caminho

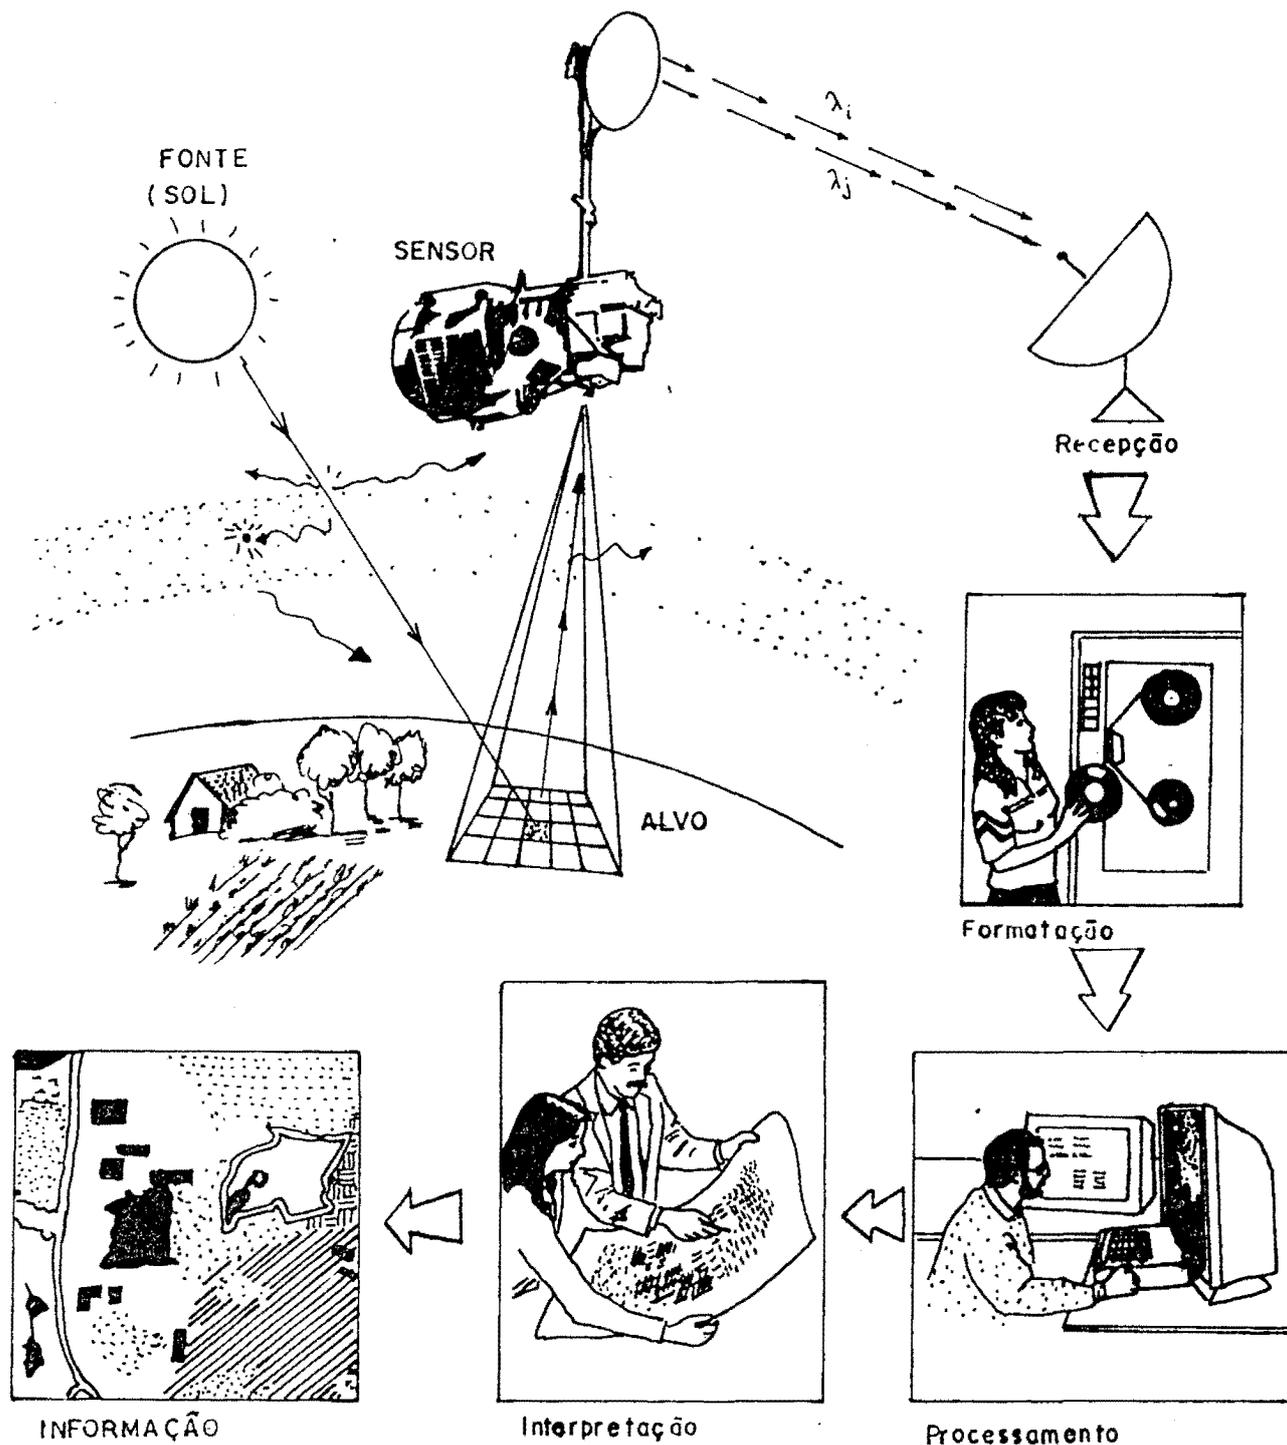


FIGURA 2.1: O processo de aquisição de informações com técnicas de sensoriamento remoto

atravessa a atmosfera com a qual interage de duas maneiras distintas, nos fenômenos conhecidos como espalhamento e absorção de energia. O espalhamento ocorre quando a radiação solar é refletida ou refratada por partículas presentes na atmosfera. Nele a energia não é atenuada e sim redirecionada, não ocorrendo perda de energia. Já no fenômeno da absorção uma parcela da radiação é absorvida pela atmosfera com o que a atmosfera é aquecida.

Os efeitos atmosféricos são seletivos em relação ao comprimento de onda da energia. Na figura 2.2 pode ser apreciada a diferença entre a irradiância solar no topo da atmosfera, e na superfície da Terra. Observa-se que a energia, ao atravessar a atmosfera terrestre, é afetada com maior intensidade em algumas regiões do espectro eletromagnético.

A radiação incidente, finalmente, interage com os elementos situados na superfície da Terra (alvos). Como resultado, e dependendo da natureza e condições do alvo, uma fração da energia é refletida, outra é absorvida e uma terceira pode ser transmitida através do alvo. A radiação que é refletida, nas faixas do visível e infra-vermelho próximo, ou reemitida, em comprimentos de onda maiores, atravessa a atmosfera, sofrendo novamente os efeitos atmosféricos, até chegar ao sensor localizado no satélite. O sensor registra esta energia junto com outras provenientes da atmosfera e a transforma em um sinal passível de transmissão à Terra para subsequente análise. Os sinais captados pelas estações terrestres são formatados em fitas magnéticas compatíveis com computador para posteriormente serem pré-processados, com a finalidade de melhorar sua qualidade, através de eliminação de ruídos e da introdução de correções geométricas.

Estas fitas são distribuídas aos especialistas e usuários, os quais, na fase prévia à interpretação, podem melhor adequar esses dados aos seus interesses, mediante processamento digital. A interpretação dos dados colhidos pode ser feita visualmente ou pelo uso de rotinas computacionais que ajudam, por exemplo, mediante

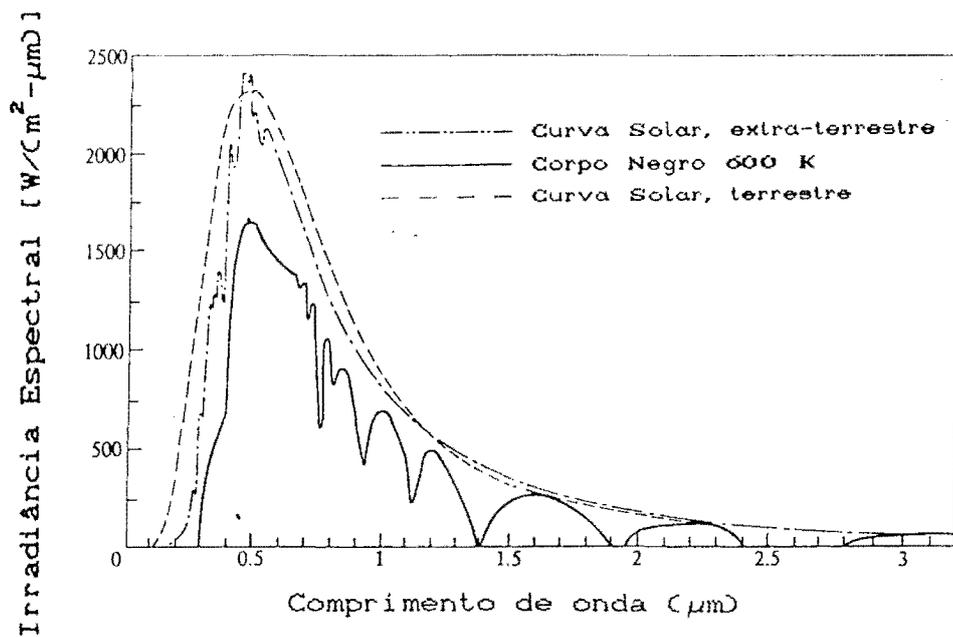


FIGURA 2.2: Efeitos atmosféricos em relação ao comprimento de onda. Energia no topo da atmosfera e na superfície da Terra (Swain e Davis 1981)

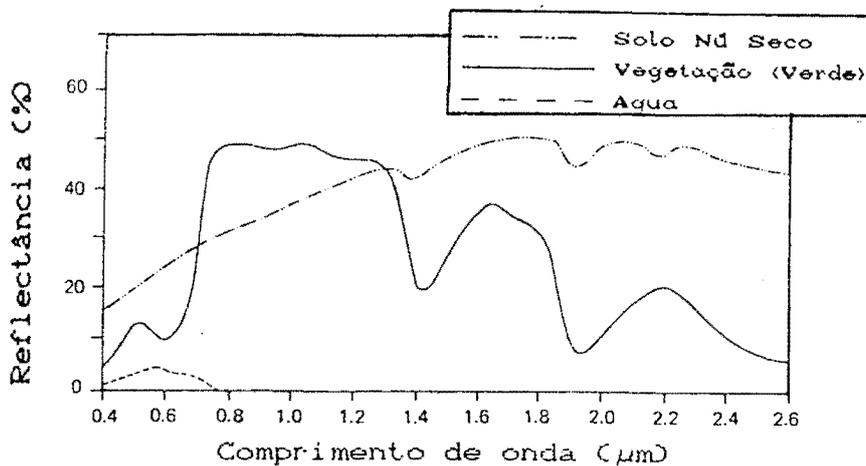


FIGURA 2.3: Resposta espectral em função do comprimento de onda para Solo, Vegetação e Água (Kiefer Lillesand).

algoritmos de classificação supervisionada ou não, e elaboração de imagens temáticas. A interpretação e análise dos dados conduz a conclusões sobre a natureza e estado dos alvos.

2.3. Características Espectrais de Alvos e Sistemas Sensores

A radiação incidente no alvo é em parte refletida pela sua superfície e o resto é transmitida ou absorvida pelo material que compõe o alvo. Tanto a absorção, como a transmissão e a reflexão, são selectivas em relação ao comprimento de onda e específicas para cada tipo particular de material, em função de sua estrutura atômica e molecular. Esta relação está detalhadamente descrita em Slater [1980]. Na presente dissertação, ela não será estudada em detalhe. De uma maneira simplificada, o balanço de energia no alvo poder ser equacionado da seguinte forma:

$$\text{energia incidente} = \text{energia refletida} + \text{energia transmitida} + \text{energia absorvida}$$

O objetivo básico do sensoriamento remoto é o estudo de alvos a partir da energia proveniente dos mesmos que é captada pelo sensor em determinadas faixas de comprimento de onda. No caso mais geral, isto corresponde à combinação da energia refletida e da emitida pelo alvo.

Já que a radiação refletida por cada material que ocupa a superfície da Terra depende da natureza e do estado do mesmo, a aplicação de técnicas de sensoriamento remoto exige o conhecimento e compreensão das características espectrais desta ampla variedade de elementos e dos fatores que as influenciam.

A figura 2.3 mostra, de uma forma geral, a distribuição da reflectância ao longo do espectro visível para três alvos típicos da superfície da Terra: solo, vegetação e água. Embora a representação gráfica seja uma generalização, ela serve para ilustrar as diferenças entre estas três grandes categorias de alvos.

Dentro da região visível do espectro grande parte da radiação é absorvida pelos pigmentos nas folhas das plantas. Há pouca transmissão de energia. A energia que não é absorvida pela planta é principalmente refletida. Nas faixas em torno de 0.45 e 0.65 μm , o que corresponde às cores azul e verde do visível, a reflectância é baixa. Isto é causado pela alta absorção da energia por parte da clorofila nestes comprimentos de onda. Entre estes picos de absorção se encontra uma região de relativa alta reflectância, com seu pico localizado em torno de 0.54 μm , o que corresponde à cor verde. Por este motivo as folhas da vegetação sadia são verdes para o olho humano. Quando a planta se encontra em uma situação de deficiência hídrica, sua produção de clorofila cai, o que diminui a quantidade de energia absorvida nas faixas em torno de 0.45 e 0.65 μm . Em tal estado, as folhas da planta têm maior reflectância, particularmente na região correspondente à cor vermelha, dando uma coloração amarela/alaranjada à folha.

Na região do infra-vermelho próximo, a vegetação sadia absorve pouca energia em relação à região do visível. A resposta espectral nesta região é controlada principalmente pela estrutura interna da folha.

Se na parte visível do espectro diferentes tipos de vegetação mostram respostas espectrais muito similares entre si, na região do infra-vermelho próximo culturas diferentes produzem diferenças na reflectância. Por essa razão, essa região do espectro eletromagnético é de grande importância no processo de discriminação de tipos diferentes de vegetação.

Três bandas de absorção, devido a água contida na planta, aparecem na faixa do infra-vermelho médio, em 1.4 , 1.9 e 2.7 μm , sendo que a maior corresponde a 2.7 μm . Entre elas ocorrem dois picos de reflectância, localizados em torno de 1.6 e 2.2 μm . A absorção de energia incidente no infra-vermelho médio depende da quantidade de água presente na folha que , por sua vez, é função da percentagem do

teor de umidade e espessura da folha.

O teor de umidade tem uma grande influência na resposta espectral da vegetação. Na medida em que o seu valor decresce, aumenta marcadamente a reflectância no infra-vermelho médio.

De um modo geral, a reflectância dos vários tipos de solos cresce na medida em que o comprimento de onda aumenta, particularmente na parte visível e no infra-vermelho próximo do espectro. A transmitância em solos é nula, conseqüentemente a energia incidente é absorvida ou refletida.

A complexa mistura de materiais que formam os solos afeta tanto suas características de absorptância como de reflectância. A maioria dos solos apresenta, de forma geral, um comportamento similar ao representado na figura 2.3. Como acontece na vegetação, o efeito da água é determinante na resposta espectral dos solos. Ela é responsável pelos picos de absorção situados em torno de 1.4, 1.9 e 2.7 μ m. O teor de umidade está diretamente relacionado à granulometria do solo. As areias, por serem bem drenadas, mostram baixa retenção de umidade, ao contrário do que acontece com as argilas, que mostram alta retenção de umidade em função de serem mal drenadas. O tamanho das partículas também age de outra maneira no balanço de energia dos solos. Mantendo constante a composição do solo, quanto menor for o tamanho da partícula, sua superfície será mais plana e lisa, fazendo com que a energia refletida seja maior.

Outros fatores que afetam a reflectância dos solos são o teor de matéria orgânica, e de óxidos de ferro. Devido a esta complexidade de parâmetros torna-se difícil discriminar as componentes individuais do solo que afeta sua reflectância em determinado momento ou situação geográfica. No entanto, a discriminação dos solos expostos em relação a outros alvos torna-se relativamente fácil.

A água pura tem baixa reflectância na região visível do espectro e

absorve praticamente a totalidade da radiação incidente nas regiões do infra-vermelho médio e próximo. Nessas últimas portanto, quase nenhuma energia é refletida. Sua reflectância é maior nos comprimentos de onda correspondentes à porção visível do espectro. No caso da água, uma pequena parcela da energia incidente é refletida pela superfície do corpo de água, outra parte é refletida pelo material que forma o fundo. A parcela mais importante é a refletida por materiais em suspensão, quando existentes.

Experiências realizadas com água destilada constataram que a absorção no visível abaixo de $0.6\mu\text{m}$ é muito pequena, e que nesta região a transmissividade é alta. A transmitância diminui na medida em que aumenta a turbidez da água. Isto quer dizer que as águas com alto teor de sedimentos em suspensão, águas turvas, refletem maior quantidade da radiação incidente. A transmitância da água é maior em torno de $0.48\mu\text{m}$, por isso que nesta parte do espectro a penetração da radiação eletromagnética é maior, permitindo portanto uma interação desta com partículas em suspensão.

A clorofila, quando presente na água, também afeta sua resposta espectral. Existem outros fatores que alteram a reflectância da água. Eles podem estar presentes na forma de materiais em suspensão ou dissolvidos e seus efeitos são muito variados, dependendo do material.

As características acima citadas são de interesse no posicionamento das faixas dentro do espectro ótico onde os sensores deverão operar. Sendo a intenção dos sensores identificar e discriminar melhor os elementos na superfície da Terra, os sensores são localizados em regiões onde a resposta espectral dos alvos é de significativa diferença.

Atualmente, existe uma série de satélites e sensores fornecendo imagens multiespectrais da superfície da Terra. As imagens presentemente mais utilizadas nas atividades relacionadas aos recursos naturais são as obtidas pelos satélites da série LANDSAT e do SPOT. A

série Landsat teve seu início no começo da década dos 70. Até o momento já foram colocados em órbita 5 satélites desta série, com progressivas modificações orientadas a aprimorar os equipamentos responsáveis pela coleta de dados. O sistema TM (Thematic Mapper) opera com 7 bandas espectrais e é atualmente muito difundido nos estudos de recursos naturais. O satélite SPOT (System Probatoire d'Observation de la Terre) foi lançado pela França em 1986 em associação com a Bélgica e Suécia. Uma relação das principais características destes sistemas é mostrada na tabela 2.1.

2.4. Imagens Digitais

Um sistema sensor a bordo de um satélite registra, de uma forma contínua, a radiação refletida e/ou emitida pela porção de superfície da Terra, que está sendo recoberta, e dentro de um campo de visada instantâneo (IFOV) (tabela 2.1). Desta forma, é gerado um sinal que pode ser registrado por uma antena receptora na Terra, na forma de um sinal analógico. Posteriormente este sinal é discretizado e colocado na forma digital. Logo, uma imagem digital consiste de uma série de elementos discretos, chamados de "pixels" (do inglês picture element). Associado a cada pixel temos um número que, de alguma maneira, representa a radiância média emitida, ou refletida, pela área coberta pelo pixel. Isto torna a imagem possível de ser manipulada através de computadores. Quando uma dessas imagens é apresentada numa unidade visualizadora de imagens, a cada ponto na tela corresponderá um valor digital de brilho (nível de cinza), representativo da radiação média do pixel no terreno.

Pode-se entender uma imagem digital como sendo uma matriz de I linhas por J colunas onde para cada posição $(i1, i2)$, com $0 \leq i1 \leq I-1$ e $0 \leq i2 \leq J-1$, existe um valor discreto x representando a radiância média correspondente a tal posição na imagem. No caso das imagens multiespectrais é necessário um número de matrizes igual ao número de bandas que a compõem, isto é, para cada posição $(i1, i2)$ na imagem corresponde um vetor p -dimensional \underline{x} (p sendo igual ao número de

bandas) cujos elementos são os níveis de cinza em cada uma delas.

TABELA 2.1: Características dos sistemas sensores usados no estudo dos recursos naturais.

sensor :	Landsat TM	Landsat MSS	SPOT/HRV
altitude (km)	695	920 - 692	822
bandas espectrais (μm)	[1] 0.45-0.53	[1] 0.5-0.6	[1] 0.50-0.59
	[2] 0.52-0.60	[2] 0.6-0.7	[2] 0.61-0.68
	[3] 0.63-0.69	[3] 0.7-0.8	[3] 0.79-0.89
	[4] 0.76-0.90	[4] 0.8-1.1	[p] 0.52-0.73
	[5] 1.55-1.75		
	[6] 10.4-12.5		
	[7] 2.08 1.35		
IFOV (m)	30 x 30 (1-5,7)	76 x 76 (1-3)	20 (1-3)
	120 x 120 (6)	80 x 80 (4)	10 (p)
resolução espacial (m)	30 x 30 (1-5,7)	57 x 82 (1-3)	20 (1-3)
	120 x 120 (6)	57 x 80 (4)	10 (p)
res. radiométrica (Bits/pixel)	8	6	8 (1-3) 6 (p)

* O satélite SPOT carrega dois sensores os quais contam com uma certa liberdade de giro (sistema de atitude). Com isto eles podem ser apontados em determinadas direções, pelo que existe a possibilidade de visão estereoscópica.

Fonte : Schowengerdt (1983)

2.4.1. Atributos das Imagens

A análise e interpretação de uma imagem exige a exploração das diferentes maneiras de captar informação da cena, ou seja, a exploração dos atributos da imagem. Eles podem ser classificados como espectrais, espaciais, temporais e contextuais.

Os atributos espectrais se referem ao valor da energia refletida ou emitida por cada pixel nas bandas espectrais disponíveis. Os atributos espectrais são o meio mais simples de se obter informação de uma imagem, em função do variado comportamento espectral dos alvos na Terra ao longo do espectro eletromagnético e da facilidade de serem quantificados, fato que é especialmente importante nos processos de

classificação assistidos por computador.

Por atributos espaciais se entendem as associações geométricas entre os pixels e suas respostas espectrais, como por exemplo: a forma, textura, dimensão ou linhamentos. A representação bidimensional da imagem evidencia tais associações, pois nela passam a se identificar conjuntos de pixels com respostas espectrais diferentes ou similares que podem formar manchas ou linhas, que possuem tamanho, forma ou direção passíveis de interpretação.

Os atributos temporais se referem às variações nos demais atributos de uma imagem em relação ao tempo. Por exemplo, alvos como a vegetação se comportam de maneira diferente em cada estágio de seu ciclo de crescimento, pelo que a análise destas variações pode ser uma fonte de informação no estudo de imagens multiespectrais de uma mesma área em diferentes épocas do ano. A resposta espectral dos alvos pode ser alterada ao longo do tempo por fatores como chuvas, umidade, ação antrópica ou processos naturais.

Os atributos de contexto se referem à relação existente entre a resposta espectral de um pixel e a região circunvizinha na imagem. Landgrebe (1980) afirma que pixels espacialmente próximos têm suas respostas espectrais altamente correlacionadas, pelo que existe uma quantidade de informação a respeito de um pixel contida na sua vizinhança imediata. Da mesma forma, o restante da cena fornece alguma informação a respeito do pixel, embora a sua avaliação seja mais difícil.

1	1	1	1	1	0	0	0	0
1	1	1	1	0	0	0	0	0
1	[?]	1	1	0	0	0	0	0
1	1	1	0	0	0	0	0	0
1	1	0	0	0	0	0	0	0

Figura 2.4: Exemplo de informação contextual

No exemplo da figura 2.4 existe um indivíduo cujo valor é desconhecido. Embora não se disponha de nenhuma restrição quanto ao valor possível que possa assumir, uma análise do resto do conjunto

sugere que tal valor se encontra "muito provavelmente" entre 0 e 1. Mais ainda, se existe uma relação espacial entre indivíduos adjacentes, como sugere o resto do conjunto, a imediata vizinhança do pixel desconhecido sugere uma forte tendência a favor do valor 1 para a incógnita. Esta análise é um exemplo da exploração dos atributos de contexto, que pode ser aplicada em imagens digitais.

A distribuição espacial dos diferentes alvos que compõem uma cena natural não é aleatória. Elementos de mesma natureza tendem a aparecer agrupados, indicando existir uma probabilidade conjunta de ocorrência entre eles. Naturalmente, tal distribuição varia de cena para cena, pelo que a probabilidade conjunta deve ser estimada para cada uma delas. No entanto, considerando este fator, pode-se fazer uso do contexto espacial dos elementos para deduzir informações a respeito dos alvos que formam a cena.

2.4.2. Características das Imagens Digitais

Quando um sistema sensor é projetado, uma série de decisões devem ser tomadas que vão definir as características das imagens digitais por ele obtidas. São levantadas questões como: a que intervalo de tempo (período) deve o satélite passar sobre o mesmo ponto na Terra (resolução temporal), ou quantos e que tipo de sensores deve ele carregar (resolução espectral). Tais características influenciam diretamente o processo de interpretação e o proveito que o usuário pode obter de uma imagem.

A resolução temporal de uma imagem é o tempo transcorrido entre duas passagens sucessivas do satélite sobre o mesmo ponto na Terra. Quanto menor for a resolução temporal do satélite, melhor se poderá acompanhar fenômenos com mudanças mais rápidas. Isto é útil em estudos, como por exemplo, de identificação de tipos de culturas vegetais, seu estágio de desenvolvimento, detectar mudanças na cobertura vegetal com o passar do tempo ou monitoramento do fluxo de sedimentos em um corpo de água. Os satélites utilizados hoje

apresentam diferentes resoluções temporais. Por exemplo o sistema Landsat-TM tem resolução de 16 dias, já o sistema SPOT tem resolução de 25 dias a qual pode ser diminuída em função da sua capacidade de movimentar e orientar seus sensores. Satélites meteorológicos (como o GOES), devido à natureza do fenômeno para o qual foram projetados, apresentam resolução temporal muito mais alta (30 minutos).

A resolução espacial determina a densidade de pixels por unidade de área representada na imagem. Para uma área constante, quanto mais pixels forem utilizados para representar esta área, maior será a resolução espacial empregada. Uma consequência do aumento da resolução espacial é a diminuição do tamanho do pixel. Por isso quanto maior for a resolução espacial de uma imagem, maior é o grau de detalhamento que se pode obter dos objetos na imagem. Por exemplo, uma situação onde o sistema instalado no satélite discretiza a cena observada em pixels de 10x10 Km não é útil para identificar estradas ou rios na imagem. Por eles terem dimensões inferiores ao tamanho do pixel da imagem, a sua radiação confunde-se com a do resto dos objetos dentro do pixel de 10 Km de lado, geralmente solo ou vegetação. Usando um pixel de 10x10 m passa-se a identificar rios, estradas e construções com maior precisão. Com pixels de 1m seria possível definir carros e árvores dentro da cena. A resolução espacial das imagens de sensoriamento remoto não pode ser aumentada livremente, pois existem outros fatores que a restringem, como o aumento da quantidade de dados a serem manipulados e armazenados ou o fato de que alguns países possuem áreas, militares ou estratégicas, que não desejam que sejam conhecidas em detalhe pela maioria do público.

Existe uma grande variedade de fatores que alteram a resposta espectral de alvos como solo, vegetação ou água, ao longo de todo o espectro eletromagnético ou em regiões específicas dele. A ação da atmosfera também prejudica o processo de aquisição de informação em alguns comprimentos de onda. Por estes motivos, o posicionamento das bandas nas quais os sensores trabalharão, dentro do espectro, torna-se importante e deve ser cuidadosamente escolhido, segundo os fins

pretendidos. A filosofia da escolha das bandas para os sensores tende a selecionar regiões do espectro onde os processos específicos da interação entre a energia eletromagnética e o material constituinte de alguns alvos resultem em características espectrais particulares. Assim, em muitos casos, as pesquisas dos materiais sobre a Terra podem ser mais eficientes quando realizadas em bandas estreitas. As limitações que restringem a escolha destas bandas são resultado da complexidade de parâmetros como o tamanho do pixel, a transmissão ótica, a atenuação atmosférica, a relação entre sinal e ruído (signal-to-noise-ratio) e o armazenamento de dados (Kaufmann et alii.1986). Desta maneira, a escolha das bandas nas quais os sensores trabalham define a resolução espectral do sistema sensor e, conseqüentemente, da imagem.

Uma vez definidas as bandas para a medição da energia proveniente do alvo, é preciso também definir a resolução radiométrica da imagem. Já que a radiação eletromagnética que atinge um sensor é descrita por um número digital, é necessário estabelecer uma "escala" para medir tal radiação. Por exemplo, se o sensor tem uma "escala" com unicamente dois valores (0,1), a cena por ele captada resultaria em uma imagem em preto (0) e branco (1), sem tons de cinza intermediários, onde (0) corresponde à ausência de energia suficiente para ativar o sensor (preto) e (1) acontece quando o sensor capta suficiente energia para ativá-lo (branco). Com uma "escala" de 11 números, de zero a dez, obtém-se uma imagem em preto e branco com 9 níveis de cinza intermediários, o que aumenta a informação contida na imagem em relação à anterior. Na medida em que se aumenta o número de níveis de cinza intermediários entre o preto e o branco, cresce o tamanho da "escala", o que em termos mais apropriados equivale a dizer que a resolução radiométrica da imagem é aumentada, com o que pode-se obter maior quantidade de informação dela. A resolução radiométrica também está condicionada a fatores limitantes como por exemplo: a relação sinal/ruído dos dados (signal-to-noise-ratio) e o nível de confiabilidade dentro do qual se deseja discriminar dois níveis de cinza (Slater 1980). Computacionalmente também existe uma limitação,

pois à maior resolução radiométrica corresponde uma maior quantidade de espaço de memória no computador. As imagens do Landsat utilizam 8 bits para armazenar e manipular os dados de cada pixel, o que corresponde a 256 níveis de cinza. Já as imagens fornecidas pelo SPOT fornecem 256 níveis de cinza nas bandas 1, 2 e 3 que operam com 8 bits por pixel, e 64 níveis de cinza na banda pancromática (6 bits).

2.4.3. Utilização de Imagens Digitais

2.4.3.1. Processamento de Imagens Digitais

Por tratamento de imagem sob forma digital, entende-se uma série de operações realizadas em computadores, tais como filtragem, manipulação de contraste e classificação. A imagem na forma digital possui a vantagem de ser suscetível a inúmeras formas de manipulação mediante o uso do computador, o que se deve ao fato dela ser representada por um arranjo de números, que permite a implementação de algoritmos segundo as necessidades do estudo realizado.

Uma transformação largamente empregada nas imagens digitais é o processo de filtragem. A filtragem espacial é uma transformação do pixel não somente em função do seu número digital, mas também dos valores dos pixels vizinhos a ele. O efeito que a filtragem tem sobre a imagem pode ser: a eliminação de ruídos presentes nos dados originais, suavização ou realçamento da imagem e manipulação de contraste da imagem.

2.4.3.2. Classificação Digital de Imagens

A parte da manipulação digital de imagens que mais interessa ao presente estudo é aquela referida aos processos de classificação e, em especial, à classificação multiespectral. O processo de classificação digital visa substituir a interpretação visual, que envolve critérios subjetivos, por um conjunto de decisões objetivas (Schowengerdt 1983). A implementação de processos de classificação em computadores pretende

auxiliar e, se for necessário, substituir o analista nas situações em que ele tenha uma interpretação muito vaga ou ambígua no processo de classificação da cena. Ela proporciona um processo alternativo mais quantitativo e que pode ser repetido várias vezes fornecendo sempre o mesmo resultado, o que não acontece com as classificações visuais onde a interpretação do analista, baseada em critérios subjetivos, tem um papel decisivo no produto final da classificação.

A finalidade do processo de classificação é atribuir um indivíduo, descrito por um vetor de estado, a uma entre várias classes especificadas previamente. Quando aplicado a uma imagem digital, o processo de classificação multiespectral é o de atribuir um pixel a uma das várias possíveis classes pré-determinadas que se suspeita existir na imagem. O produto final, que se deriva deste processo, é uma imagem temática na qual cada pixel está representado como membro de uma classe. As maneiras de realizar esta tarefa são diversas. Existem vários algoritmos de classificação digital, alguns deles baseados em princípios da teoria de decisão estatística e outros de natureza essencialmente determinística. Todos eles procuram tornar o processo de mapeamento da superfície terrestre menos subjetivo e capaz de ser repetido sistematicamente, sem comprometer o produto da classificação.

O vetor de estado utilizado na classificação multiespectral é composto pelos números digitais correspondentes ao pixel nas bandas espectrais selecionadas. Utilizando duas bandas espectrais, por exemplo, esse vetor teria a dimensão igual a dois, e o espaço dentro do qual o vetor poderia assumir valores formaria um plano. O valor da leitura em cada banda pode variar entre zero e um limite superior, que no caso do sistema Landsat é 255.

Um dos algoritmos de classificação mais simples é o chamado de "fatiamento" (gray level slicing). Esta técnica utiliza unicamente uma banda espectral e consiste em dividir os níveis de cinza em faixas (ou fatias). Cada uma dessas faixas corresponderia a uma classe. A relação entre as classes e as faixas é geralmente obtida a partir do

levantamento de um histograma da frequência relativa de níveis de cinza na banda estudada. Desta forma, todos os níveis de cinza contidos numa faixa passam a ser representados por um mesmo valor, que significa a classe. Posteriormente, é relacionada uma cor a cada um desses valores e com isto se constrói uma imagem temática.

A técnica conhecida como do "paralelepípedo" ou dos "hipercubos" (single cell) consiste basicamente em uma extensão do processo anterior para o caso de duas ou mais bandas espectrais utilizadas simultaneamente. Nela faz-se uma análise prévia dos histogramas em cada banda com a finalidade de se determinar o intervalo dentro do qual se espera estar contida a maioria dos indivíduos de cada classe em cada banda. Assim, fixam-se intervalos de variação de cada variável em cada classe. Pode-se imaginar esta situação com duas bandas, com um sistema de dois eixos coordenados, cada um correspondendo a uma variável (ou banda), a interseção de tais intervalos no plano formam retângulos que representam as classes. Aqueles pixels cujos vetores de estado estiverem contidos dentro de um destes retângulos são atribuídos à classe correspondente. Em se tratando de três dimensões, a região associada a cada classe adota a forma de um paralelepípedo.

Outra possível abordagem é aquela baseada nos princípios de distância mínima em relação aos vetores das médias que descrevem cada classe. O processo se inicia calculando as médias dos números digitais correspondentes a cada classe em cada uma das bandas, as quais compõem o vetor de médias. Para que tal vetor seja representativo da classe de interesse, é necessário que na imagem existam regiões bem características de cada classe formando aglomerados no espaço multiespectral, a partir das quais possa ser estimado o vetor de médias. O processo continua classificando todos os pixels na imagem segundo um critério de distância, o que equivale a dizer que um pixel, cuja classe é desconhecida, é classificado calculando as distâncias, no espaço multiespectral, entre o seu vetor de estado e os vetores de médias de cada classe. O pixel é atribuído à classe cujo vetor de médias estiver associado à menor distância. Existe uma grande

variedade de conceitos da distância que podem ser utilizados para tal finalidade, no entanto, a distância geralmente empregada é a distância euclidiana.

Uma classificação estatística muito difundida nos estudos de sensoriamento remoto é a Máxima Verossimilhança baseada na teoria de Bayes, onde se assume que os níveis digitais dos pixels na imagem seguem uma distribuição normal. As diferentes classes são caracterizadas pelo vetor de médias (\underline{m}_h) e a matriz de covariância (Σ_h) que são estimados a partir de amostras de cada classe na imagem. Isto é realizado pelo operador do sistema que, com conhecimento de certas áreas da cena, pode identificar grupos de indivíduos pertencentes às classes e com eles alimentar a informação necessária para estimar os parâmetros.

A aplicação dos processos de classificação de imagens de satélite tem tido largo emprego no estudo dos recursos naturais, e tornou-se um aliado importante nos estudos de bacias hidrográficas. Em se tratando de informação do estado da cobertura superficial de bacias e sua tradução a parâmetros de modelos hidrológicos, o trabalho de coleta de dados por via convencional é difícil e consome muito tempo, especialmente em grandes áreas. Ragan [1975] aponta que freqüentemente a fase de coleta de dados requer muito mais tempo que a de aplicação do modelo e sua interpretação posterior. Fazendo uma comparação entre coleta de dados a respeito da cobertura vegetal usando fotografias aéreas (em escala 1/4800) e imagens Landsat, ele conclui que a análise e mapeamento da informação, para a região que ele pesquisou, obtida pelo primeiro processo requer muito mais tempo (aproximadamente 94 dias-homem) em comparação ao processamento digital de imagens Landsat (menos que 4 dias-homem) e que a precisão da informação fornecida pelos dados Landsat é compatível com aquelas requeridas por muitos modelos usados em hidrologia urbana.

Tao [1989] implementou informações ao respeito da cobertura e uso do solo obtidas a partir de imagens LANDSAT em um modelo de previsão

de enchentes. Notou melhora na previsão dos picos de escoamento e escoamento total a um nível de significância de 10%.

Também nas atividades de inventário da bacia hidrográfica o sensoriamento remoto se torna um aliado do hidrólogo. Os estudos de uso e ocupação do solo relativos à área a ser inundada pelos reservatórios na bacia hidrográfica do rio Paraíba do Sul conduzidos por Paiva Filho et alii. (1986) mostram que as imagens Landsat são adequadas ao objetivo pretendido e são poderosas auxiliares nos estudos de planejamento integrado, em especial nos de bacias hidrográficas, tanto pela qualidade do produto como pela quantidade de informações obtidas, além de permitir estudos comparativos ao longo do tempo. Além disso, foi verificado que a classificação digital apresenta alta precisão nesta tarefa e que é possível esperar bons resultados dela, especialmente em regiões de relevo pouco acidentado onde o efeito da sombra na resposta espectral dos alvos é pequeno e a estimativa da área ocupada por cada classe não é afetada pela inclinação do terreno em relação ao plano da imagem.

Em se tratando de extensas áreas o custo da coleta de dados por meio de técnicas de sensoriamento remoto apresenta-se vantajoso em relação a outras alternativas. Por exemplo, um quadrante de uma imagem Landsat, na forma de fita compatível com computador (CCT), cobre uma área aproximada de 8556.25 Km² na forma de um quadrado de 95,2 Km de lado, e pode ser obtida periodicamente, desde que as condições atmosféricas na região o permitam. No caso da série Landsat as imagens são obtidas a cada 16 dias, mas podem ser prejudicadas pela presença de núvens e a projeção de sua correspondente sombra sobre partes da imagem. Mais ainda, existe um arquivo histórico de imagens digitais da série Landsat.

Estas características, além da variedade de bandas espectrais de cada sensor, evidenciam a vantagem do uso de imagens obtidas a partir de sensores instalados em satélites em estudos que envolvam grandes áreas em relação a outras técnicas, como a fotografia aérea, cujo custo

é superior e não conta com a periodicidade, nem a riqueza do arquivo histórico, nem a variedade espectral da informação das imagens de satélites.

Deve-se ter presente que em estudos que requeiram um maior detalhe, a fotografia aérea ainda é mais vantajosa que as imagens de satélite. Na escolha da melhor alternativa para determinado estudo deve-se considerar tanto as vantagens como as limitações de cada sensor ou técnica escolhida. Dependendo da tarefa a ser executada, freqüentemente a combinação de várias técnicas será mais apropriado.

2.5. Revisão de Experiências no uso de Atributos de Contexto no Processo de Classificação

A utilização de contexto no processo de classificação de imagens digitais por computador constitui-se em um campo de pesquisa que vem ocupando a atenção de um número crescente de pesquisadores. Neste capítulo é feita uma revisão dos principais trabalhos já desenvolvidos nessa área.

Para Nagy [1984], o reconhecimento de padrões assume um papel importante nas atividades do sensoriamento remoto devido aos recentes avanços nas técnicas de extração de informação. O desenvolvimento de novos e mais sofisticados procedimentos de classificação, segundo ele, podem resultar em técnicas automáticas de bom desempenho na abordagem de problemas como monitoramento de áreas agrícolas, levantamento de recursos naturais e mapeamento da cobertura superficial da Terra. Como exemplo faz referência ao trabalho desenvolvido por Haralick e Shapiro (1979,1980) na área de integração das componentes espaciais, temporais e espectrais de uma mesma cena. Nagy reconhece a importância da abordagem utilizada por estes autores à procura da combinação dos métodos estatísticos de classificação espectral e a exploração dos atributos de contexto e espaciais com as técnicas de reconhecimento de padrões e inteligência artificial. Da mesma forma sugere que a transição da análise local (por pixel) ao desenvolvimento de uma

interpretação global de imagens corresponderia na prática a uma forma sistemática de utilizar a cobertura superficial do solo como fonte de informação que, combinada com outras fontes de informação auxiliares (como mapas de solos, relevo, entre outros), pode servir para fins de obtenção de informação a respeito do uso do solo, do ecossistema ou habitat.

A exploração dos atributos de contexto inquieta à comunidade de pesquisadores do sensoriamento em remoto, devido ao potencial que oferece no incremento da precisão das classificações de imagens digitais e a possibilidade de eliminar pixels isolados ("inliers") dentro de áreas homogêneas. Justice e Townshend [1982], ao estudar trabalhos de classificação em imagens Landsat correspondentes à área de Basilicata na Itália, observaram que, utilizando informação contextual juntamente com a espectral, pode-se atingir um aumento em torno de 4% na precisão global da classificação quando comparada com uma classificação puramente espectral. Esses pesquisadores implementaram seus conceitos em uma rotina (RECLASS), parte do sistema IDIMS (Interactive Digital Image Manipulation System). Por meio desta função é analisada a classificação dos oito vizinhos mais próximos ao pixel pesquisado. A classe mais freqüente nesta vizinhança é determinada e comparada com a do pixel central. Se ambas forem iguais não haverá mudanças no pixel e o pixel seguinte será analisado. Por outro lado, se forem diferentes, se considera que o pixel está mal classificado e que a classe correspondente ao pixel central é aquela mais freqüente, previamente determinada na vizinhança. Com isto se corrige a imagem temática reduzindo a presença de pixels isolados dentro de regiões homogêneas.

Outra maneira de abordar o uso do contexto é proposta por Wharton [1982], que desenvolveu um algoritmo de análise contextual (CONAN-Contextual Analysis) como parte de um estudo de classificação de diferentes tipos de uso do solo. Sua motivação foi a necessidade de uma metodologia que aproveitasse os atributos de contexto adequados aos casos de imagens com baixa resolução espacial onde, ao contrário

do que ocorre com as imagens comumente usadas, as classes presentes não ocupam áreas extensas e contínuas (em relação às dimensões do pixel), mas apresentam-se fragmentadas em termos de distribuição espacial. Essa configuração resulta na presença de mais de uma classe em cada pixel individual ("pixel mistura"). Este é o caso, por exemplo, de imagens obtidas em zonas urbanas onde a diversidade dos elementos que as formam dificulta a discriminação de áreas espectralmente homogêneas. A classe "área-comercial" não resultará espectralmente homogênea, mas será uma mistura de pixels com características de asfalto, prédios e vegetação. A classe "área-residencial" poderá ter os mesmos três elementos, mas a proporção da mistura destes pixels será diferente. Na classe "área-residencial" aparecerá maior quantidade de vegetação, talvez menor quantidade de pixels com resposta espectral de telhado e poderá até aparecer um novo elemento, correspondente a prédios, com novas características espectrais em função do diferente material utilizado na sua construção.

A rotina CONAN pode ser dividida em três fases: A primeira é uma classificação puramente espectral, onde os métodos convencionais de classificação podem ser utilizados, sendo recomendadas pelo autor as técnicas de agrupamento (clustering). O resultado desta fase é uma imagem já classificada, isto é, uma imagem temática. Na segunda fase é definida uma região, que pode ser uma janela quadrada de 3x3 até 45x45 pixels, a qual pesquisa a imagem temática, atribuindo ao pixel central um vetor. A dimensão do vetor é igual ao número de classes presentes em toda a cena. Os elementos do vetor correspondem à frequência das classes dentro da região compreendida pela janela. Na terceira fase se executa a classificação dos vetores mediante uma técnica de agrupamento não paramétrica, utilizando um histograma multidimensional armazenado na forma de tabela, para definir os grupos.

A partir da segunda fase CONAN não utiliza a informação espectral na sua forma original (o número digital em varias bandas), mas baseia-se na informação resumida da imagem temática resultante da

primeira fase, isto é, cada pixel é descrito por um único número digital correspondente a uma classe. Segundo Wharton, CONAN é eficiente na identificação de tipos de uso do solo na base da distribuição de frequências das classes presentes na cena. CONAN não é entretanto capaz de classificar satisfatoriamente a imagem quando a diferença entre os tipos de uso do solo é caracterizada basicamente por atributos espaciais, como por exemplo a repetição de algum padrão. Da mesma forma, CONAN não produz um bom resultado na sua identificação quando a frequência das classes na região compreendida pela janela utilizada não é suficiente para caracterizar o tipo do uso do solo.

Moller-Jensen [1990] desenvolveu uma metodologia de classificação usando atributos espaciais (textura), espectrais (reflectância) e de contexto em uma imagem TM da área urbana em Bangkok. Devido à diversidade de classes presentes neste tipo de cenas, inicialmente as áreas ocupadas por água e vegetação são classificadas espectralmente, pixel a pixel. Essas áreas ocupam uma fração pequena da imagem e apresentam também maior homogeneidade quanto a características espectrais e são, portanto, classificadas espectralmente de forma relativamente fácil. Deve ser tomado o devido cuidado para considerar neste passo somente as áreas de vegetação e água com relativa grande extensão, deixando de lado os pequenos pontos em torno das construções os quais podem ser afetados pela presença de sombra, que altera as características espectrais dos pixels. Desta maneira, a parcela da cena não classificada está ocupada por diferentes grupos de pixels, os quarteirões da cidade, cada segmento sendo ocupado por uma complexa combinação de alvos correspondentes ao tipo e grau de intensidade de ocupação urbana do solo. Para delimitar tais grupos é utilizado um processo de detecção de linhas com o intuito de discriminar as ruas e canais, os quais passam a ser considerados como os limites naturais dos elementos presentes na cena. O processo inclui restrições capazes de evitar a classificação de pequenos trechos de ruas saindo das principais para minimizar o número de classificações erradas. No espaço bidimensional, estas linhas servem como limites das figuras que se formam a partir da sua combinação e interseção. No caso de imagens

de áreas urbanas, as ruas e canais delimitam as figuras que corresponderiam a quarteirões, parques e outras construções ou áreas verdes. Desta maneira a imagem é dividida em segmentos os quais passam a ser tratados como unidades, embora dentro deles exista uma grande variedade de pixels.

O seguinte passo é classificar cada segmento segundo suas características espectrais, de textura e de contexto. Para cada segmento, obtido pelo processo de detecção de linhas, são calculados a média e o desvio padrão do nível de cinza em cada uma das bandas espectrais, bem como as coordenadas do seu centro geográfico. Isto é realizado a partir do conjunto dos pixels que compõem o segmento. A informação contextual é incorporada usando a seguinte abordagem: A vizinhança de cada um destes segmentos é determinada como sendo o conjunto dos segmentos com centros geográficos dentro de um raio de distância pré-determinado em torno dele. Esta abordagem, embora simples de implementar, apresenta desvantagens quando um segmento adjacente é muito grande. Nesse caso, seu centro geográfico pode ficar relativamente afastado de forma que passa a não ser mais considerado como parte da vizinhança. O conceito de centro de um segmento é ainda utilizado para incluir outro tipo de informação, por exemplo a distância entre cada segmento e alguns pontos chave, como por exemplo o centro da cidade, o que fornece informação a respeito da posição do segmento dentro da cena toda. Esta informação é útil na determinação do tipo de uso do solo.

Não somente em imagens da superfície da Terra são usados os atributos de contexto para realizar classificações mais precisas. Kittler e Pairman [1985] desenvolveram uma regra de classificação contextual para ser aplicada na determinação da cobertura total de núvens e a identificação de seus diferentes tipos e formas. O método recursivo idealizado para esta finalidade se inicia com uma classificação espectral segundo o método da Máxima Verossimilhança para variáveis com distribuição gaussiana, seguida de um processo iterativo, o qual leva em consideração a relação contextual entre o

pixel de interesse e seus oito vizinhos mais próximos. A regra de decisão é baseada em termos das probabilidades de transição entre pares de pixels vizinhos. O processo iterativo continua até se alcançar a situação em que todos os pixels na imagem permaneçam estáveis em relação à sua classificação dentro de uma das classes pré-estabelecidas.

O processo foi testado em imagens da série NOAA-7, as quais têm características diferentes das séries Landsat e SPOT, tais como a dimensão do pixel de 1 Km, resolução radiométrica de 10 bits e diferentes bandas espectrais, mais adequadas ao estudo da atmosfera. Os resultados obtidos nesta experiência demonstraram que muitas classificações imperfeitas foram filtradas e corrigidas pelo processo contextual. A formação de áreas não homogêneas na imagem temática, resultante do método da Máxima Verossimilhança, especialmente nas regiões de fronteira entre classes diferentes, foi corrigida utilizando a informação contextual, com o que resultou uma melhor diferenciação entre as áreas ocupadas pelas classes. Notou-se também que o processo utilizado não é capaz de corrigir agrupamentos de pixels mal classificados relativamente grandes. Isto se atribui ao fato dos pixels que formam estes conglomerados tender a confirmarem-se mutuamente, reduzindo dessa forma a eficácia do conceito de contexto.

Estudos conduzidos por Mohn, Hjort e Storkiv [1987], visando testar e comparar vários métodos de classificação contextual em imagens multiespectrais, confirmam o fato dos processos contextuais reduzirem a proporção de erros cometidos em relação aos métodos que utilizam atributos puramente espectrais, e facilitarem a identificação de estruturas presentes na cena. Entre suas conclusões está registrado o bom funcionamento da exploração de contexto em áreas homogêneas e em bordas com estruturas simples, como por exemplo aquelas formadas por poucas e grandes linhas retas. Bordas com estruturas mais complexas podem também ser identificadas pelos métodos contextuais quando reforçados por fatores de incerteza que identifiquem regiões da cena onde o contexto não aporte como fonte de informação e, pelo contrário,

introduza classificações erradas na imagem temática. Nas experiências de Kittler e Pairman [1985], se comprovou que, se existe uma forte dependência espacial associada ao ruído nos dados que compõem a cena, isto é, se os pixels caracterizados como ruído estão próximos uns dos outros formando grupos maiores, a sua remoção da imagem temática por métodos de classificação contextual torna-se difícil e a precisão da classificação diminui. Apesar disso, estes pesquisadores ressaltam que a relação espacial deve ser levada em consideração, já que esta dependência existe na prática e sua importância aumenta na medida em que a resolução espacial cresce.

Uma das mais conhecidas metodologias para a extração de informação a partir dos atributos contextuais junto aos espaciais e espectrais de uma imagem é a desenvolvida por David Landgrebe [1980]. O resultado de nove anos de trabalho de sua equipe oferece uma série de procedimentos de reconhecimento de padrões para imagens obtidas por satélites, agrupados no que passou a se chamar ECHO (Extraction and Classification of Homogeneous Objects) nas suas formas supervisionada e não supervisionada.

A ideia básica em ECHO consiste em dividir a imagem em pequenos grupos, chamados de células, usando uma grade regular. Cada célula é então submetida a um teste estatístico de homogeneidade. Aquelas células que não satisfazem o teste são classificadas pixel a pixel e deixam de ser tratadas como grupo. O passo seguinte é o agrupamento das células, que são vizinhas e compostas por mais de um pixel, segundo outro critério estatístico de similaridade, baseado numa forma generalizada do teste da razão de verossimilhança (likelihood ratio). Desta maneira, os grupos vão se combinando formando grupos maiores, até atingir seus limites naturais, o que ocorre quando o teste de similaridade para as células não é satisfeito. O resultado do processo de Landgrebe possibilita a segmentação da imagem em áreas homogêneas.

Os testes realizados levaram a concluir que a precisão de ECHO é maior que aquela obtida pelo processo de Máxima Verossimilhança pixel

a pixel. As imagens temáticas obtidas com ECHO apresentam maior grau de generalização (suavização espacial) e por isso são mais fáceis de utilizar. Também foi notado que ECHO é um algoritmo computacionalmente mais eficiente que o da Máxima Verossimilhança.

ECHO, na sua forma supervisionada (SECHO), é eficiente para classificar arranjos de dados que contenham objetos homogêneos os quais são grandes em relação à resolução espacial do sensor. Anuta et alii. [1984] utilizaram SECHO na classificação de imagens Landsat TM e verificaram um aumento na precisão global que vai de 95%, com a classificação por pixel, a 97,9% usando SECHO (Di Zenzo et alii.1989).

Uma abordagem estatística do problema do uso do contexto em classificações digitais de imagens multiespectrais é adotada por Swain, Vanderman e Tilton [1981], os quais desenvolveram uma regra de decisão baseada em uma função que levasse em conta a influência do contexto na classificação dos pixels. O desenvolvimento desta metodologia contextual faz uso da teoria de decisão composta. O modelo proposto é uma generalização do classificador por Máxima Verossimilhança. Diferentes tipos de vizinhança foram testados com este algoritmo. Os testes foram realizados em imagens sintéticas geradas para esta finalidade, bem como em imagens da série Landsat. Os resultados obtidos com o primeiro tipo de imagem foram alentadores e comprovaram que o uso da informação contextual melhora a precisão da classificação. Já os resultados com imagens reais foram menos satisfatórios e mostraram que o aumento na precisão é função da precisão com que a relação contextual entre pixels pode ser estimada.

Continuando nesta linha de pesquisa, Tilton et alii.[1982] propõem um estimador estatístico não tendencioso da função de contexto que tem a vantagem de se adaptar às situações onde as estimativas da função contextual variam segundo as características espectrais de cada região da imagem. A classificação contextual utilizando o estimador não tendencioso, aplicada a uma imagem Landsat produziu uma imagem temática mais apropriada à interpretação visual que aquela obtida com

informações puramente espectrais, devido à tendência registrada na informação de contexto de dar um efeito de uniformização na imagem. Este efeito não acontece em todas as regiões da imagem, mas somente onde a informação contextual assim o indicar. Houve um aumento da precisão na classificação em todas as experiências realizadas por estes autores, que utilizaram os quatro vizinhos mais próximos na extração dos atributos de contexto para cada pixel.

Com a finalidade de comparar a redução de erros cometidos na classificação multiespectral de imagens pixel a pixel, Eklundh et alii.[1980] realizaram um estudo no qual são utilizadas três técnicas que visam reduzir erros de classificação, pela implementação do conceito de contexto :

- pré-processamento: Esta tarefa foi realizada mediante a implementação de um filtro do tipo passa baixas nas diferentes bandas que formam a a imagem. O filtro empregado utiliza uma janela 3x3, a qual se desloca ao longo da região estudada. Em cada banda se determina o valor do pixel central e entre seus oito vizinhos adjacentes escolhendo-se aqueles seis pixels cujos números digitais forem mais próximos do central. O valor final atribuído ao pixel central resulta da ponderação dos números digitais destes seis vizinhos e do pixel central. Após a filtragem espacial das bandas, estas são utilizadas para fins de classificação espectral, considerando que seu valor foi espectralmente corrigido pela filtragem. O processo de classificação empregado utiliza o conceito da distância de Mahalanobis em relação aos vetores de médias das classes previamente determinadas. Ou seja, cada pixel é classificado como pertencente à classe cujo vetor de médias estiver espectralmente mais próximo do vetor de números digitais do pixel, segundo a distância de Mahalanobis.

- pós-processamento: Primeiro a cena foi classificada segundo o conceito da distância de Mahalanobis. Posteriormente se realizou uma reclassificação baseada na comparação da classe atribuída a cada pixel com o número de ocorrências das outras classes na sua vizinhança. Isto equivale a dizer que um pixel que foi classificado como sendo de uma

classe será atribuído a uma nova classe se um determinado número de pixels vizinhos mais próximos pertencem à esta última classe.

- processos de relaxação: Testou-se o processo de classificação probabilística seguida de ajustes iterativos. Utilizou-se, para isto, a técnica de relaxação probabilística que é um método para estimar a probabilidade que associa cada pixel a cada classe, através de aproximações sucessivas às probabilidades verdadeiras, e desconhecidas, na base dos valores das probabilidades dos oito vizinhos mais próximos e do próprio pixel na iteração anterior.

O autor conclui que as primeiras duas técnicas apresentam desvantagens. No pós-processamento se utiliza um mínimo de informação dos pixels, já que unicamente se considera a classe atribuída ao pixels sem levar em consideração a relação espectral do pixel com as outras classes. Já o pré-processamento frequentemente introduz uma suavização indesejada na imagem prejudicando a qualidade da imagem temática produzida pela classificação.

Os testes realizados, mostraram que os dois primeiros processos apresentaram resultados equivalentes no que diz respeito à redução do erro. A relaxação proporcionou uma melhora muito mais significativa, já que se verificou uma diminuição no número de erros aproximadamente quatro vezes maior quando comparado aos outros métodos usados.

Di Zenzo et alii. [1989] elaboraram um processo de classificação contextual complementar ao da Máxima Verossimilhança baseada em atributos espectrais. Nele, as probabilidades associadas a cada uma das classes de interesse, para cada pixel, são corrigidas iterativamente em função das probabilidades correspondentes aos pixels vizinhos. Os processos iterativos utilizados pelos autores são a relaxação probabilística e a relaxação "fuzzy". Ambos métodos incluem, na sua formulação um fator que leva em consideração a relação espacial entre pixels de várias classes, conhecido como coeficiente de compatibilidade. Imagens sintéticas e imagens reais Landsat foram utilizadas para teste do método. Constatou-se que houve um aumento na

precisão da classificação, tanto no processo de relaxação probabilística como no de relaxação fuzzy, embora tenha-se verificado uma convergência mais rápida para a relaxação fuzzy no caso de imagens sintética.

Um processo combinado, composto de quatro iterações probabilísticas seguidas de quatro fuzzy, demonstrou ser mais eficiente, e foi portanto empregado nas imagens Landsat. Os resultados obtidos com estas imagens não demonstraram a mesma eficiência quando comparados com os obtidos com imagens sintéticas, mas mesmo assim, ocorreu uma melhoria com relação ao processo de Máximo Verossimilhança. Os autores chamam a atenção ao fato do processo contextual ter a capacidade de corrigir erros, mas também existir risco da inclusão de novos erros, o que geralmente não é acusado pela medição da precisão global da classificação. Tais erros acontecem geralmente nos cantos e bordas dos segmentos que compõem a cena.

Como Haralick [1983] faz notar, os atributos de contexto constituem-se em uma das principais diferenças quando se compara os métodos utilizados pelo cérebro humano no processo de entendimento de uma cena e aqueles correntemente disponíveis em computadores, como são os algoritmos para reconhecimento de padrões. O autor ainda chama a atenção para o fato das técnicas de reconhecimento de padrões, geralmente aplicadas em imagens digitais se basearem, principalmente, na suposições seguintes:

a) O processo de descrição é realizado pixel a pixel. Isto é, quando a unidade (o pixel) "i" está sendo examinada, não são analisadas características de outras unidades fora dela para caracterizá-la.

b) As medidas realizadas na unidade "i" depende exclusivamente da interpretação associada à unidade "i" e não depende de qualquer relação que esta unidade possa ter com outras unidades ou a interpretação associada a qualquer outra unidade.

O reconhecimento de padrões, sem levar em consideração os

atributos de contexto, assume que as unidades (ou pixels no caso de uma imagem digital) são independentes entre si, isto é, que a classe de um pixel não está correlacionada com as classes dos pixels vizinhos. Essa última suposição, obviamente, não é correta em se tratando de imagens naturais.

III METODOLOGIA

3.1. A Classificação pelo Método da Máxima Verossimilhança

O problema da classificação de cada pixel na cena pode ser abordado do ponto de vista da teoria de decisão estatística, considerando que a reflectância (na forma de número digital) associado a um pixel constitui-se em uma variável aleatória. A hipótese de normalidade para pixels em uma classe será também assumida no presente estudo. Essa suposição é justificada pelas observações realizadas até hoje utilizando imagens de cenas naturais, podendo ainda ser entendida como uma consequência do teorema do limite central.

No caso multivariado assume-se que cada observação, vetor de estado do pixel (\underline{x}), pode ser considerado um vetor de variáveis aleatórias, cujas componentes são as leituras da energia que atingem o sensor, em cada uma das bandas espectrais consideradas ($x_1, x_2, x_3, \dots, x_p$). A decisão a ser tomada é a classificação do pixel descrito pelo vetor p -dimensional (\underline{x}) em uma das "m" classes possíveis presentes na cena (ω_h , $h=1,2,3,\dots,m$ com $\omega \in \Omega$). Seja qual for a decisão tomada, existe sempre uma probabilidade de erro associada a ela. Um critério comumente adotado consiste em atribuir cada pixel à classe que minimiza a probabilidade de erro dentro das suposições acima mencionadas. Uma teoria de classificação matematicamente viável e que satisfaz a condição anterior é a Máxima Verossimilhança baseada na teoria de Bayes (Duda e Hart 1973).

O princípio de decisão de Bayes está baseado na suposição que (ω) , o parâmetro da distribuição da variável aleatória (\underline{x}), é também uma variável aleatória, e que a distribuição ("a priori") de (ω) , denotada por $P(\omega)$, é conhecida (Pal 1986). Para fins de classificação, as diferentes classes são caracterizadas pelo vetor de médias e a matriz de covariância típica de cada classe. Considerando uma população de "n" indivíduos, os estimador não tendenciosos para o

vetor de médias e a matriz de covariância são dados por:

$$\underline{m}_h = \frac{1}{n} \sum_{i=1}^n (\underline{x}_i)$$

$$\Sigma_h = \frac{1}{n-1} \sum_{i=1}^n \left[(\underline{x}_i - \underline{m}_h)' * (\underline{x}_i - \underline{m}_h) \right]$$

Sendo \underline{x}_i o vetor correspondente a um indivíduo conhecido membro da classe h.

Para classificar um pixel se deseja conhecer as probabilidades "a posteriori" do pixel pertencer a cada uma das classes de interesse (ω_h), dado que o pixel possui o vetor de estado (\underline{x}) (Schowengerdt 1985). Pelo teorema de Bayes, a probabilidade "a posteriori" é :

$$P(\omega_h | \underline{x}) = [p(\underline{x} | \omega_h) * P(\omega_h)] / p(\underline{x})$$

As funções representadas com letras maiúsculas denotam distribuições discretas. Já aquelas escritas com letras minúsculas representam funções contínuas.

$P(\omega_h | \underline{x}_i)$ é a probabilidade "a posteriori" da classe ω_h acontecer dado que o pixel \underline{x}_i acontece.

$p(\underline{x} | \omega)$ é a função contínua que representa a distribuição do vetor de números digitais dentro da classe ω_h . No caso discreto é representada por $P(\underline{x} | \omega_h)$.

$P(\omega_h)$ é a probabilidade "a priori" da classe ω_h na área classificada, considerando que ω_h tenha uma distribuição discreta.

$p(\underline{x}_i)$ é a probabilidade do pixel \underline{x}_i acontecer.

Para o caso de " ω " ser uma variável contínua:

$$p(\underline{x}) = \int_{\omega}^{+\infty} p(\underline{x} | \omega) * p(\omega) d\omega$$

ou no caso de " ω " ser uma variável discreta, que é o de interesse no presente caso :

$$p(\underline{x}) = \sum_{h=1}^m p(\underline{x}|\omega_h) * P(\omega_h)$$

Esta é a função densidade de probabilidade incondicional de \underline{x} para a classe $\omega_h \in \Omega$. Onde Ω deve ser exaustivo, isto é, não devem existir outras classes na imagem além das contidas em Ω . Da mesma forma as classe ω_h devem ser mutuamente excludentes.

Um vetor medido (\underline{x}) será classificado como pertencendo à classe ω_h se a probabilidade "a posteriori" associada a ω_h para \underline{x} for a maior entre as possíveis. Isto é :

$$\text{Máx } P(\omega_h|\underline{x}) = [p(\underline{x}|\omega_h) * P(\omega_h)] / p(\underline{x})$$

Como o interesse é determinar qual classe está relacionada à maior probabilidade "a posteriori", o valor de $p(\underline{x})$ passa a ser irrelevante pois tem um valor independente de ω_h . Neste caso, eliminando $p(\underline{x})$ da expressssão, o vetor de estado do pixel será classificado dentro da classe cujo valor seja o máximo para $D_h(\underline{x}) = p(\underline{x}|\omega_h) * P(\omega_h)$, que se torna a função discriminante para o método da Máxima Verossimilhança.

Finalmente resulta uma expressão da regra de decisão de Bayes do tipo: Atribuir o pixel à classe ω_h se:

$$D_h(\underline{x}) > D_k(\underline{x}) \quad \text{com } h \neq k \quad k = 1, 2, 3, 4, \dots, m$$

Em algumas situações acontece que duas ou mais funções discriminantes assumem o mesmo valor, que ao mesmo tempo é o máximo do conjunto, para um determinado pixel. Para estas situações, um critério de decisão deve ser pré-estabelecido, mas geralmente se realiza uma escolha aleatória sem maiores prejuizos (Duda e Hart 1973).

Para facilitar a implementação deste processo em computadores e reduzir o número de cálculos que ele necessita, outras funções

discriminantes podem ser deduzidas considerando que as fronteiras ou limites de decisão entre classes permanecem iguais se uma função monotônica de $D_h(\underline{x})$ é utilizada (Swain et alii. 1978). Por exemplo:

$$D_h(\underline{x}) = \ln [p(\underline{x}|\omega_h) * P(\omega_h)]$$

Duda e Hart [1973] mostram que a lei de decisão de Bayes minimiza a probabilidade média de erro global se todas as classes têm funções de densidade de probabilidade gaussianas. Em sensoriamento remoto, as classes mostram ter distribuições que podem, na maior parte dos casos, ser muito bem aproximadas pela distribuição normal multivariada. Assumindo $p(\underline{x}|\omega_h)$ como sendo uma função densidade de probabilidade gaussiana com vetor de médias \underline{m}_h e matriz de covariância Σ_h tem-se :

$$p(\underline{x}|\omega_h) = \left\{ \frac{(2*\pi)^p}{|\Sigma_h|^{-1}} \right\}^{-1/2} * \exp \left\{ -\frac{1}{2} * (\underline{x}_i - \underline{m}_h)' \Sigma_h^{-1} (\underline{x}_i - \underline{m}_h) \right\}$$

- $h=1,2,\dots,m$
- $| \cdot |$ simboliza o operador norma euclidiana da matriz
- p denota a dimensão do vetor \underline{x}

A função discriminante assume a forma :

$$\begin{aligned} D_h(\underline{x}) &= \ln [p(\underline{x}|\omega_h) * P(\omega_h)] \\ &= \ln [p(\underline{x}|\omega_h)] + \ln [P(\omega_h)] \\ &= (-n/2) \ln(2\pi) - (1/2) \ln |\Sigma_h| \\ &\quad - (1/2) (\underline{x} - \underline{m}_h)' \Sigma_h^{-1} (\underline{x} - \underline{m}_h) + \ln [P(\omega_h)] \end{aligned}$$

Adotando probabilidades "a priori" iguais para todas as classes $\ln [P(\omega_h)]$ torna-se uma constante que, junto a $(-n/2) \ln(2\pi)$ pode ser desconsiderado. Com isto, a função discriminante finalmente adotaria a forma:

$$D_h(\underline{x}) = - (1/2) \ln |\Sigma_h| - (1/2) (\underline{x} - \underline{m}_h)' \Sigma_h^{-1} (\underline{x} - \underline{m}_h)$$

A distribuição "a priori" de cada classe $P(\omega_h)$ pode ser estimada a partir de trabalhos anteriores realizados na mesma área de estudo, fotografias aéreas ou outras fontes. Quando este tipo de informação não existe ou não é muito confiável, geralmente se adota igual probabilidade "a priori" para todas as classes, com o intuito de evitar tendenciosidade ao assumir valores falsos de $p(\omega_h)$ (Schowengerdt 1980). Strahler [1980] salienta que o uso das probabilidades "a priori", quando conhecidas, pode ser uma ajuda efetiva para melhorar a precisão da classificação.

Fazendo uma rápida análise da função discriminante acima desenvolvida, em suas várias formas de apresentação, se observa a introdução da matriz de covariância na sua composição. O termo quadrático $(\underline{x} - \underline{m}_h)' \Sigma_h^{-1} (\underline{x} - \underline{m}_h)$, que aparece nas funções discriminantes descritas acima, corresponde à função distância estatística ou também conhecida como a distância de Mahalanobis. A diferença da distância euclidiana $(\underline{x} - \underline{m}_h)' (\underline{x} - \underline{m}_h)$, a distância de Mahalanobis considera a distribuição da população \underline{x} no espaço das bandas espectrais ao calcular a distância, pela inclusão da inversa da matriz de covariância. Para o espaço bidimensional (usando duas bandas espectrais) no caso da distância euclidiana, os pontos equidistantes de \underline{m}_h formam uma circunferência em torno de \underline{m}_h . Já na distância de Mahalanobis estes pontos formam uma elipse com o eixo maior paralelo à direção de maior variação de \underline{x} . Os eixos passam pelo ponto dado por \underline{m}_h e a forma da elipse está definida pela forma quadrática :

$$(\underline{x} - \underline{m}_h)' \Sigma_h^{-1} (\underline{x} - \underline{m}_h)$$

O processo de classificação pelo método da Máxima Verossimilhança é considerado puramente espectral. Devido ao fato da classificação do pixel na posição "i" depender unicamente do vetor dos níveis de cinza em cada banda \underline{x}_i , exclusivamente atributos espectrais da imagem estão sendo explorados. Neste caso, não está se considerando a posição relativa do pixel na imagem, a provável classificação dos seus vizinhos, ou qualquer outro tipo de informação espacial, temporal ou

contextual a respeito do pixel "i". A função discriminante utilizada neste processo utiliza informação somente no espaço multiespectral definido pelas bandas da imagem, como os vetores de médias, as matrizes de covariância e os vetores de estado (\underline{x}) dos pixels.

3.2. A Implementação do Conceito de Contexto em uma Imagem Digital

A exploração do contexto tem a finalidade de aumentar a exatidão do processo de classificação, utilizando a informação oriunda de pixels vizinhos. O problema neste sentido é a classificação do pixel em função da classificação da sua vizinhança. Esta tarefa, um tanto simples para o cérebro humano, exige uma série de considerações a fim de ser implementada em um algoritmo de computador. A principal delas, e a que maior influência tem sobre a classificação contextual, é a definição da vizinhança em torno do pixel a ser analisado.

Em uma imagem digital, a vizinhança de um pixel é composta por um conjunto de pixels, os quais podem compor diferentes arranjos, variando em forma e tamanho. Tal vizinhança é chamada, para fins de tratamento e classificação digital, de janela. Swain et alii. [1981] definem a janela como sendo um sub-conjunto de observações das variáveis pesquisadas (agrupadas no vetor \underline{x}). Este sub-conjunto inclui, junto à própria observação em questão (\underline{x}_{i_1, i_2}), na posição (i_1, i_2) da matriz que forma a imagem, n-1 observações espacialmente próximas, mas não necessariamente adjacentes a \underline{x}_{i_1, i_2} . As n-1 observações servem como o contexto espacial para o pixel \underline{x}_{i_1, i_2} e são tomadas na mesma posição espacial relativas à posição (i_1, i_2) , para todos os valores possíveis de i_1 e i_2 .

Existe uma variedade de arranjos que satisfazem esta definição de contexto, fato que Swain et alii. [1980] comentam. Algumas janelas possíveis são mostradas na figura 3.1 mas nem todas são utilizadas em tratamento digital de imagens, em parte devido às limitações impostas pelo elevado tempo de computação resultante da utilização de janelas de dimensões maiores.

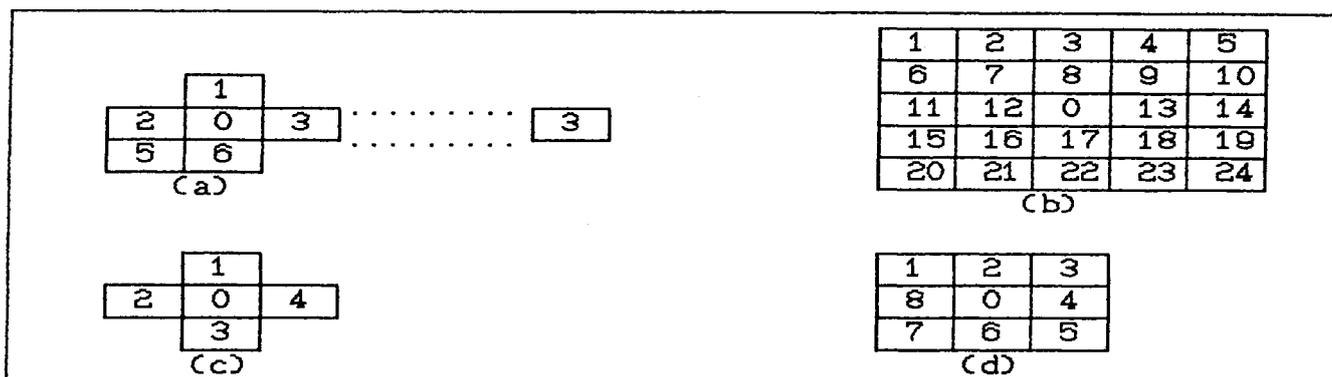


Figura 3.1: Exemplos de janelas utilizadas em imagens digitais

Como Landgrebe [1980] comenta, é observado que pixels espacialmente próximos estão correlacionados, sendo que tal correlação decresce na medida em que a distância entre estes aumenta. De uma forma geral, a correlação cai lentamente com a distância e uma separação da ordem de vários pixels é necessária para que ela atinja valores não significativos. Sendo assim, o maior valor para a correlação está associado a pixels adjacentes, pelo que janelas como as mostradas nas figuras 3.1.c e 3.1.d são as mais freqüentemente empregadas em processos digitais.

Por serem simétricas em relação ao pixel central e portanto invariantes com relação à rotação da imagem, janelas com dimensão igual a um número ímpar de pixels são geralmente as mais utilizadas. Nestas janelas, pode-se atribuir a mesma importância a pixels vizinhos que se encontram à mesma distância do pixel central. Desta forma, a informação obtida a partir da janela pode ser mais apropriadamente atribuída ao pixel central.

Janelas do tipo mostrado da figura 3.1 não estão definidas para pixels nas bordas da imagem por não existirem elementos suficientes para compor o arranjo pré-determinado. Por este motivo, os algoritmos que empregam este tipo de janelas deixam de lado as regiões próximas às bordas da imagem. A largura das faixas não incluídas pelos algoritmos depende do arranjo que define a janela.

3.3. Processos de Relaxação

A técnica de relaxação, aplicada ao processo de classificação, pode ser resumidamente descrita da seguinte maneira. Utilizando um dos vários métodos disponíveis (Máxima Verossimilhança, por exemplo) é feita uma classificação inicial. Desta forma é obtida, para cada elemento em X , uma estimativa para o valor das probabilidades associadas a cada classe em Ω . Conhecidos esses valores inicia-se o processo de relaxação. Nesse processo, de uma forma iterativa e segundo um critério determinado, os valores das probabilidades associando elementos em X a classes em Ω são ajustadas. O critério adotado relaciona o vetor das probabilidades estimadas para cada elemento em X com aqueles estimados para os elementos vizinhos. Desta forma a noção de contexto é introduzida no processo de classificação. O processo iterativo é interrompido quando as variações entre duas iterações sucessivas for inferior a um limiar previamente escolhido. Quando este processo iterativo finaliza, a classe associada a cada pixel é decidida pelo valor da probabilidade final entre as diferentes classes.

A idéia do uso efetivo dos processos de relaxação na solução de problemas de classificação foi primeiramente utilizada por Rosenfeld et alii. [1976]. Basicamente, a tarefa de classificação consiste em atribuir cada um dos elementos \underline{x} do conjunto X de indivíduos observados ($\underline{x} \in X$) a uma classe ω , dentro de um conjunto de classe Ω ($\omega \in \Omega$). A solução para este problema sugerida por Rosenfeld et alii. estabelece um processo, baseado nos métodos de relaxação, que utiliza a relação entre o indivíduo a ser classificado \underline{x}_i e um outro indivíduo \underline{x}_j para fins de classificação de \underline{x}_i . Para fins deste estudo, o conjunto de indivíduos X é formado pelos pixels que compõem uma imagem descritos pelos seus vetores de estado \underline{x} . Os processos de classificação por relaxação são um tipo de técnica iterativa, paralela, para utilizar a informação contextual com a finalidade de reduzir as ambiguidades locais (Zucker et alii. 1978).

Como todo processo iterativo, o de relaxação requer valores iniciais para as probabilidades, próximos aos verdadeiros (desconhecidos), para que a convergência ocorra. Por isto, os valores iniciais devem ser uma razoável aproximação dos valores verdadeiros da classificação. Neste tipo de processo o produto final deve, além de ser consistente com a informação contextual de cada pixel, ser também consistente com a estimativa inicial. Caso contrário poder-se-ia se concluir que a estimativa inicial não era suficientemente próxima do valor verdadeiro ou que no processo de relaxação houve alguma perda de informação.

O trabalho de Rosenfeld et alii. (1970) desenvolve várias abordagens do processo de relaxação na classificação. Dentro delas, as que são empregadas no presente estudo são a abordagem probabilística e a fuzzy. Embora o trabalho original abordasse o problema da identificação de figuras geométricas, acabou resultando em uma série de estudos posteriores orientados à solução de problemas de classificação contextual (por exemplo: Di Zenzo et alii. 1987, Richards et alii. 1981, Zucker et alii. 1974) e de textura (Hsiao et alii. 1989).

Em termos gerais, o processo de relaxação utilizado segue o roteiro seguinte: Iniciando com um conjunto de valores estimados da relação entre os pixels (x_i) e as classes (ω), cada estimativa é corrigida segundo a função :

$$p_i^{t+1}(\omega_h) = F(h , q_i^t(\omega))$$

onde "t" denota a iteração atual, $q_i^t(\omega)$ denota a contribuição da vizinhança do pixel "i", $F()$ é uma função que considera tanto a classificação do pixel "i" como a do resto da sua vizinhança e a relação existente entre tais classificações, o que geralmente se efetua através do chamado coeficiente de compatibilidade, e "h" denota a classe atribuída ao pixel "i" na iteração "t".

O contexto considerado pode adotar várias posições relativas, mas para fins do presente estudo define-se como contexto do pixel pesquisado os oito pixels mais próximos a ele e que, somado a ele, formam uma janela de 3x3 pixels, como mostrado na figura 3.6. Para identificar estes vizinhos usar-se-a a seguinte nomenclatura relativa:

1	2	3
8	0	4
7	6	5

Figura 3.2: Janela e convenção adotada no presente estudo

A escolha deste tipo de vizinhança não é arbitrária, mas se fundamenta na alta correlação existente entre pixels adjacentes. Este fato é observado na maioria das cenas do tipo Landsat e é um dos princípios fundamentais em grande parte dos estudos de classificação contextual (Landgrebe 1980, Di Zenzo et alii. 1987, Zucker et alii. 1978, Eklundh et alii. 1980, Richards et alii. 1980).

3.3.1. O Valor da Probabilidade Inicial

Para dar início ao processo de relaxação torna-se necessário estimar o valor da probabilidade do pixel "i" pertencer a cada uma das classes $p_i(\omega_h)$. Tal estimativa não deve ser arbitrária e sim ser uma boa aproximação do valor verdadeiro. Uma forma de obter tais valores é através da classificação estatística pelo método da Máxima Verossimilhança.

Pode-se descrever cada pixel, em uma imagem digital, usando um vetor que armazene os números digitais de cada banda. Assim a dimensão do vetor é igual ao número de bandas e cada um de seus elementos corresponde ao número digital associado ao pixel em uma das bandas espectrais. Esta forma de representação possui a desvantagem de desconsiderar outros tipos de informação contidas no pixel fora da espectral, como a informação contextual e a espacial. Apesar disso, pode-se utilizar este vetor, o qual é chamado de vetor de estado x_i do pixel na posição "i", para obter uma estimativa da probabilidade do

indivíduo pertencer a cada uma das classes por meio de um processo de classificação que utilize atributos espectrais. É assumido que as classes são mutuamente exclusivas e exaustivas da forma que :

$$\sum p_i(\omega_h | x_i) = 1 \quad \text{para todo } x_i \in X \text{ com } h=1,2,3,\dots,m$$

e $0 \leq p_i(\omega_h | x_i) \leq 1$ (Hsiao e Sawchuk 1989)

Para simplificar a notação, o termo $p_i(\omega_h | x_i)$ será escrito $p_i(h)$.

Assumindo que a função densidade de probabilidade das classes de interesse sigam uma distribuição gaussiana, pode-se obter uma primeira estimativa dos valores de $p_i^o(\omega_h)$ mediante o uso do processo de classificação pelo método da Máxima Verossimilhança. Fazendo uma normalização com a finalidade de satisfazer a condição :

$$\sum_{h=1}^m p_i^o(\omega_h) = 1$$

tem-se

$$p_i^o(h) = (D_h(x_i) / \sum_{k=1}^m D_k(x_i))$$

sendo $D_h(x_i)$ o valor da função discriminante obtida pelo método da Máxima Verossimilhança.

3.3.2. O Valor da Probabilidade Inicial Associada à Classe 'fundo'

É de se esperar que nem todos os pixels de uma cena tenham relação unicamente com as classes consideradas na classificação. No caso geral de classificação de imagens de sensoriamento remoto existem algumas classes, não consideradas, presentes na cena para as quais não está definido o valor da probabilidade. Dito de outra forma, as classes consideradas não são exaustivas, pelo que o somatório das probabilidades $p_i^o(h)$ não será igual à unidade. A omissão de classes no processo de classificação de uma imagem constitui-se na prática num fato inevitável pela complexidade da cena, que contém classes difíceis de serem identificadas ou de pouco interesse para o usuário.

Devido ao restrito grupo de classes de interesse estabelecido na classificação, o processo descrito acima não considera os valores de $p_i(h)$, com $\omega_h \notin \Omega$, embora o seu valor seja de interesse a fim de evitar erros de inclusão ou má classificação.

Acontece freqüentemente em imagens digitais que existem pixels, ou conjuntos deles, os quais não correspondem a nenhuma das classes de interesse ($\omega \in \Omega$). Tais pixels pertencem a classes não consideradas na classificação ou para as quais não se dispõe da função densidade de probabilidade. Dados desta natureza introduzem erros na classificação, da mesma forma que a existência de ruídos oriundos do próprio processo de aquisição de informação. O efeito que esses pixels podem ter na precisão da classificação, erros de comissão bem como os erros de omissão podem ser amenizados fazendo uso da estatística do teste do T^2 de Hotelling (Johnson e Wichern 1982).

$$n(\underline{x}_i - \underline{m}_h)' S^{-1} (\underline{x}_i - \underline{m}_h) \approx T^2$$

$$\text{com } S = \frac{1}{n-1} \sum_{i=1}^n (\underline{x}_i - \underline{m}_h)(\underline{x}_i - \underline{m}_h)'$$

$$\text{e } \underline{m}_h = \frac{1}{n} \sum_{i=1}^n (\underline{x}_i)$$

onde T^2 é uma generalização do teste t-Student que pode ser aproximado por uma função do teste de Snedecor-Fisher :

$$T^2 = n(\underline{x}_i - \underline{m}_h)' S^{-1} (\underline{x}_i - \underline{m}_h) > (n-p)p/(n-p) F_{\alpha}(p, n-p)$$

onde :
 n é o número de indivíduos da amostra
 p é a dimensionalidade ou número de bandas espectrais
 F é a estatística de Fisher com (n, n-p) graus de liberdade
 α é o nível de significância de teste

Fixando um nível de significância (α), a estatística acima define

um hiperelipsóide de confiança que deixa fora da classificação uma fração α da população daquela classe.

Aqueles que não se enquadrarem em nenhuma das classes consideradas, dentro do nível α escolhido, passam a constituir o que se chamará de "fundo" e será denotada como se fosse uma classe da forma (ω_0) . Esta não constitui-se em uma classe no sentido convencional, constituindo-se na realidade em um artifício destinado a compensar a falta do conhecimento a respeito das classes não consideradas no processo e satisfazer a condição :

$$\sum p_i(h) = 1 \quad \text{onde } h \text{ passa a ter valores de } h=0,1,2,\dots,m$$

Devido ao carácter não convencional da "classe fundo", não é possível estabelecer uma função discriminante para a mesma e sua aproximação se torna difícil, em função da necessidade da conservação do nível de significância fixado. Esta situação é contornada pela simplificação de Di Zenzo et alii. [1989] que adota um valor constante para tal função, igual ao máximo valor que a função densidade de probabilidade para qualquer classe h assume na fronteira da região de confiança, já definida pela estatística de T^2 -Hotelling.

Uma representação gráfica desta simplificação pode ser vista na figura 3.3. Nela para um mesmo nível de significância, à uma classe com menor variância (classe 1) corresponde um maior valor da função discriminante nos limites do intervalo de confiança do que à classe com maior variância (classe 2). Adotando o valor associado à classe 2 corre-se o risco de incluir na classe 1 indivíduos que seriam rejeitados caso o limiar estabelecido pela classe 1 fôsse utilizado. Por outro lado o uso do limiar associado à classe 1 implica a rejeição de indivíduos da classe 2. A solução dada por Di Zenzo et alii. [1989] embora desfavoreça às classes com maior variância opera a favor da segurança evitando que pixels que correspondem a classes não consideradas sejam incluídos dentro das classes consideradas. Os pixels incorretamente rejeitados podem ser posteriormente incluídos nas classes de maior variância pelo processo contextual.

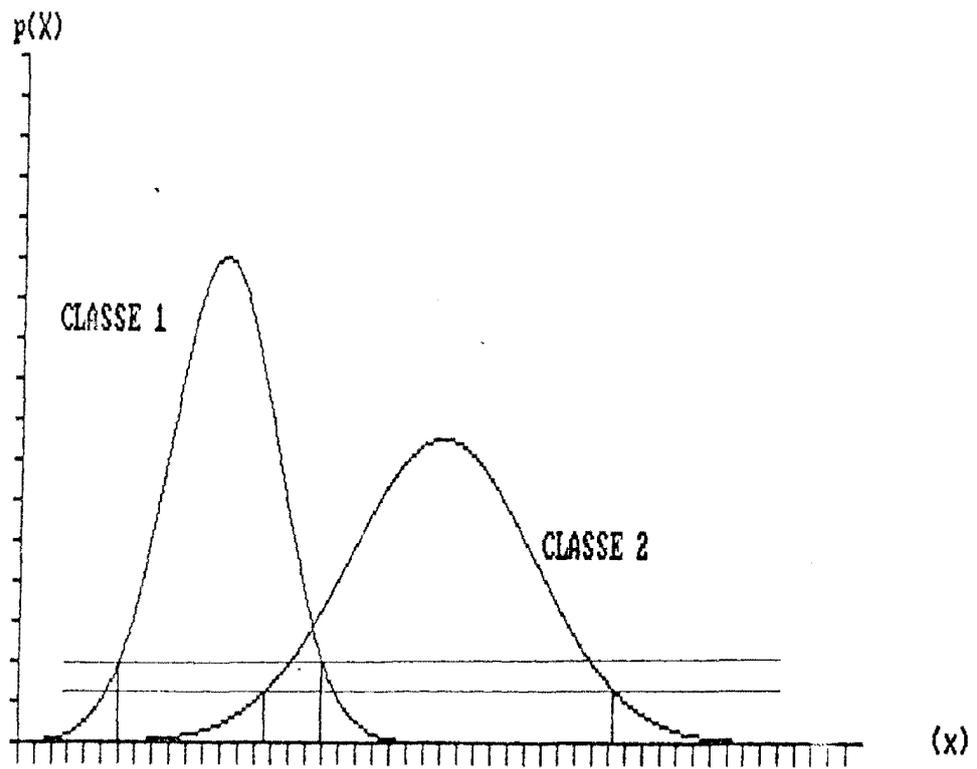


FIGURA 3.3: O valor da probabilidade inicial associada à classe "fundo"

3.3.2. Processo de Relaxação Probabilística

A maneira como o processo de relaxação probabilística altera os valores da probabilidade inicial obtidas pela Máxima Verossimilhança utilizada no presente trabalho é similar àquela seguida por Eklundh et alii. [1980], Rosenfeld et alii. e Di Zenzo et alii. [1989].

A função $F(h, q_i^t(\omega))$ no modelo probabilístico de Rosenfeld [1970] adota a forma :

$$F(h, q_i^t(\omega_h)) = q_i^t(\omega_h)$$

onde o fator $q_i^t(\omega_h)$ será o encarregado de transmitir a contribuição da vizinhança ao valor da probabilidade obtida pelos métodos espectrais.

Segundo a abordagem de Rosenfeld [1970] definimos $q_i^t(\omega_h)$ como:

$$q_i^t(\omega_h) = \sum_{j=0}^B \sum_{k=0}^m d_{ij} r_j(h,k) p_{ij}^t(k)$$

$p_{ij}^t(k)$: é o valor da probabilidade do pixel na posição "j" pertencer à classe "k" ao mesmo tempo que o pixel na posição "i" pertence a "h" na iteração "t"

t : é a iteração atual

i : identifica a posição do pixel central na janela 3x3 dentro da imagem

j : índice que identifica qualquer pixel dentro da vizinhança estabelecida. (Figura 3.2)

m : Número de classes.

d_{ij} : coeficiente que representa a influência da posição "j" no valor de $q_j(\omega_h)$.

$r_j(h,k)$: coeficiente de compatibilidade entre a ocorrência da classe "h" na posição "i" e da classe "k" na posição "j". Como o coeficiente de compatibilidade está sempre relacionado ao pixel "i" este sub-índice não é escrito.

$p_j^t(k)$: é o valor da probabilidade do pixel na posição j

pertencer à classe k

A equação anterior pode ser escrita da forma :

$$q_i^t(\omega_h) = \sum_{j=0}^0 \sum_{k=0}^m d_{ij} r_j(h,k) p_{ij}^t(k) + \sum_{j=1}^8 \sum_{k=0}^m d_{ij} r_j(h,k) p_{ij}^t(k)$$

Onde a primeira parcela da soma corresponde à posição $j=0$ que não é mais que o próprio pixel central i.

No caso especial do pixel central o coeficiente de compatibilidade assume características particulares, já que $p_{ij}^t(k)$ quando $i=j$ é igual a $p_i^t(h)$ devido que $(i \in h)$ unicamente acontece quando $(j \in h)$ acontece, logo o coeficiente adotado neste caso é da forma :

$$r_j(h,k) = 0, \text{ se } h \text{ for diferente de } k$$

$$r_j(h,k) = 1, \text{ se } h \text{ for igual a } k$$

Pelo que a primeira parcela da soma se transforma a :

$$q_i^t(\omega_h) = d_{ii} p_i^t(h) + \sum_{j=1}^8 \sum_{k=0}^m d_{ij} r_j(h,k) p_{ij}^t(k)$$

O valor de d_{ij} neste caso é assumido como sendo constante ($d_{ij}=1/8$) para todos os oito vizinhos de i e como sendo igual a 1 para i (o pixel central).

$$p_i^{t+1}(h) = q_i^t(\omega) = p_i^t(h) \left\{ 1 + \sum_{j=1}^8 \sum_{k=0}^m (1/8) r_j(h,k) p_j^t(k) \right\}$$

$$p_i^{t+1}(h) = p_i^t(h) \left\{ 1 + (1/8) \sum_{j=1}^8 \sum_{k=0}^m r_j(h,k) p_j^t(k) \right\}$$

Onde $r_j(h,k)$, o coeficiente de compatibilidade, representa a correlação existente entre $p_i^t(h)$ e $p_j^t(k)$ na imagem.

Esta regra de modificação não é suficiente para garantir que o valor das novas probabilidades fique no intervalo entre zero e a unidade. Para satisfazer esta restrição se procede a fazer uma normalização definindo o novo operador não-linear :

$$p_i^{t+1}(h) = p_i^t(h) \frac{1}{L} \left\{ 1 + \frac{1}{8} \sum_{j=1}^8 \sum_{k=0}^m r_j(h,k) p_j^t(k) \right\}$$

com :

$$L = \sum_{h=0}^m p_i^t(h) \left\{ 1 + \frac{1}{8} \sum_{j=1}^8 \sum_{k=0}^m r_j(h,k) p_j^t(k) \right\}$$

Os valores de $r_j(h,k)$ são definidos de tal forma que ficam no intervalo $[-1,1]$. Assim sendo, é interessante notar que valores altos da probabilidade $p_j(k)$, associada ao pixel vizinho, combinados com valores elevados, positivos ou negativos, de $r_j(h,k)$, possuem alta influência na alteração de $p_i(h)$.

Os efeitos da contribuição desses dois fatores são representados no quadro seguinte :

		coef. de compatibilidade	
		alto	baixo
$p_j(k)$	alta	+	-
	baixa	0	0

Tabela 3.1: Efeito do coeficiente de compatibilidade no valor da probabilidade do pixel central no processo contextual

A combinação de valores altos da probabilidade do pixel vizinho na posição "j" pertencer à classe "k" ($p_j(k)$) com valores altos do coeficiente de compatibilidade deverá ter uma alta contribuição positiva ao valor de $p_i(h)$. Já valores muito baixos para o coeficiente de compatibilidade associados a valores altos de $p_j(k)$ deverão ter efeito negativo elevado em $p_i(h)$ pois se o vizinho "j" no contexto de "i" pertence à classe "k" e esta classe é pouco compatível com a classe "h", então a classe "h" dificilmente aparecerá na posição "i".

Valores de $r_j(h,k)$ próximos de zero significam que a ocorrência da classe "h" em "i" não está associada à ocorrência da classe "k" em "j", pelo que para qualquer valor de $p_j(k)$ quando $r_j(h,k)$ for próximo de zero, o valor de $p_i(h)$ tende a permanecer constante.

Peleg et alii. [1977] sugere que o coeficiente de compatibilidade para os processos de relaxação contextual deve ter as seguintes propriedades:

- $r_j(h,k) > 0$ se $(\omega_h \ \omega_k)$ são compatíveis em $(x_i \ x_j)$
- $r_j(h,k) < 0$ se $(\omega_h \ \omega_k)$ são incompatíveis em $(x_i \ x_j)$
- $r_j(h,k) \cong 0$ se as classes de "i" e "j" são independentes.

Como a verdadeira classificação da imagem não é conhecida, os coeficientes de compatibilidade não podem ser exatamente determinados, porém, eles podem ser estimados a partir da classificação inicial (pelo método da Máxima Verossimilhança). Para que tal estimativa seja confiável, a classificação espectral deve ser razoavelmente precisa.

3.3.4. O Coeficiente de Compatibilidade de Contexto

O modelo linear de Rosenfeld [1976] presuppõe que a probabilidade $p_i(h)$ do elemento "i" pertencer à classe "h" aumenta pela ação do contexto se os elementos vizinhos possuem alta probabilidade de pertencer a classes de alta compatibilidade com a classe de "h". Analogamente, $p_i(h)$ deveria diminuir caso outras classes, não compatíveis com "h" em "i", possuem alta probabilidade na vizinhança de "i". Outro fator a ser considerado é que classes com baixa probabilidade deverão ter pouca influência em $p_i(h)$, independente da compatibilidade entre (ieh) e (jek) . Rosenfeld aponta que a correlação entre (ieh) e (jek) possui tal propriedade e que poderia ser usada para obter o valor do coeficiente de compatibilidade.

Estudos posteriores (Hsiao et alii. [1989], Eklundh et alii. [1980]) mostram que os valores de $r_j(h,k)$, que devem ser fixos ao longo do processo, podem ser obtidos a partir da informação conjunta

de (ieh) e (jek) .

Sendo $E(p_{ij}(h,k))$ o valor esperado de $p_i^o(h)p_j^o(k)$, e sendo $E(p_j^o(k))$ o valor esperado de $p_j^o(k)$, então o coeficiente de compatibilidade toma a forma :

$$r' = \ln \left(\frac{E(p_{ij}(h,k))}{E(p_i^o(h)) * E(p_j^o(k))} \right)$$

Segundo Hsiao et alii. os eventos de $p_{ij}(h,k) / [E(p_i^o(h)) * E(p_j^o(k))]$ fora de $[e^{-5}, e^5]$ podem ser ignorados pelo que considerando unicamente os valores de r' dentro do intervalo $[-5,5]$ o coeficiente de compatibilidade é definido por :

$$r' = \frac{1}{5} \ln \left(\frac{E(p_{ij}(h,k))}{E(p_i^o(h)) * E(p_j^o(k))} \right)$$

Devido à falta de uma estimativa da distribuição das probabilidades $p_{ij}(h,k)$ e seu valor esperado, deve-se procurar uma formula alternativa para obter este coeficiente. Di Zenzo et alii. [1989] propõem uma estimativa baseada no número de ocorrências das classes na área classificada que evite o calculo das probabilidades que aparecem dentro da formulação, por considerar que sempre que as classes não são exaustivas, isto é, existem pixels que não correspondem a nenhuma das classes em estudo, não se dispõe de estimativas confiáveis de $p_i^o(i \in \text{"fundo"})$, o que deriva em uma estimativa do coeficiente de compatibilidade não confiável.

A estimativa proposta por Di Zenzo é :

$$r_j(h,k) = \ln \frac{NC(j,h,k)}{\sum_{i=0}^m NC(j,h,k) \sum_{j=0}^m NC(j,h,k)}$$

onde $NC(j,h,k)$ representa o número de vezes que um pixel (não

localizado nas bordas da imagem) é classificado como "h" e, ao mesmo tempo, seu vizinho "j" é classificado como "k".

Esta forma do coeficiente de compatibilidade resulta em valores negativos muito grandes para casos onde a combinação de (ieh e jek) é pouco freqüente além de ser afetada pelo tamanho da área utilizada para fazer a estimativa. Para compensar estas deficiências no presente estudo será empregada uma combinação das duas formas anteriores. Estimando o valor esperado da probabilidade da ocorrência das classes "h" nas posições "j" a partir do número de vezes que esta combinação ocorre na imagem:

$$E [p_{i,j}^{(h,k)}] = \frac{NC(j,h,k)}{NTOTAL}$$

O coeficiente de compatibilidade pode ser escrito por:

$$r_j^{(h,k)} = \frac{1}{5} \ln \left[\frac{\frac{NC(j,h,k)}{NTOTAL}}{\sum_{j=0}^m \frac{NC(j,h,k)}{NTOTAL} \sum_{i=0}^m \frac{NC(j,h,k)}{NTOTAL}} \right]$$

onde NTOTAL é o número total de pixels presentes na área a ser classificada.

Os valores do coeficiente foram ainda truncados para a faixa entre (-1,1), segundo é proposto por Hsiao et alii. [1989].

Finalmente obtem-se, após as simplificações uma estimativa do coeficiente de compatibilidade da seguinte forma:

$$r_j^{(h,k)} = \frac{1}{5} \ln \frac{NC(j,h,k) * NTOTAL}{\sum_{j=0}^m NC(j,h,k) \sum_{i=0}^m NC(j,h,k)}$$

3.3.5. Processo de Relaxação Fuzzy

Uma maneira alternativa de representar a informação em processos de classificação ou realçamento de imagens de sensoriamento remoto está sendo atualmente explorada pela introdução da matemática fuzzy no processamento de imagens digitais. As técnicas fuzzy pretendem de alguma maneira compensar a diferença que existe entre a análise feita pelo cérebro humano e o computador. Na lógica classicamente empregada na representação de informação em tratamento de imagens, os elementos pertencem ou não a um determinado conjunto, não deixando espaço para situações intermediárias. Muitas situações, no entanto, não podem ser tratadas desta maneira rígida de classificar elementos, o que resulta em perda de informação da imagem.

A abordagem fuzzy se baseia na premissa do conceito da pertinência de um elemento a um conjunto apresentar valores gradativos e não ser rígida como tem sido implementada até recentemente em computadores. Neste sentido, tem-se mostrado crescente interesse no processamento digital de imagens (Di Zenzo et al. 1989a 1989b, Wang 1990, Pal e Dwijesh 1986).

Segundo Pal e Dwijesh [1986], um conjunto fuzzy (A) no espaço $X=\{x\}$ é uma classe de eventos com uma variação gradativa de pertinência (de x em A) caracterizada por uma função de pertinência $p_A(x)$ que associa cada ponto em X com um número real no intervalo $[0,1]$, onde o valor de $p_A(x)$ representa o grau com que x pertence a A.

Formalmente, esta relação é escrita da forma:

$$A = \{ f_A(x_i), x_i \quad i=1,2,\dots,n \}$$

n = Número de elementos

$$0 \leq f_A(x_i) \leq 1$$

A função de pertinência pode ser vista como um coeficiente de peso que reflete a ambigüidade no conjunto. Na medida em que o valor da função de pertinência cresce, aproximando-se da unidade, aumenta também o grau da pertinência do evento "x" em "A". $f_A(x_i)=1$ denota

total pertinência de x em A e por outro lado $f_A(x_i)=0$ mostra que x não pertence a A . Assim sendo, um conjunto fuzzy não tem fronteiras definidas e um elemento é livre de pertencer parcialmente a vários conjuntos.

Existe uma variedade de operadores próprios desta abordagem matemática, que podem ser encontrados em Pal e Dwijesh [1986], dentre os quais unicamente alguns serão utilizados nesta dissertação. Eles são descritos a seguir.

Seja C o conjunto de resultados da união dos conjuntos A e B é definido por $C = A \cup B$, e sua função de pertinência depende das funções de pertinência de A e B , da forma :

$$f_{A \cup B}(x) = f_C(x) = \max(f_A(x), f_B(x)) = \vee(f_A(x), f_B(x))$$

onde \vee simboliza "o máximo dos argumentos entre parêntesis".

Analogamente, a interseção de dois conjuntos fuzzy A e B com funções de pertinência $f_A(x)$ e $f_B(x)$, respectivamente, é dada por $C = A \cap B$ e a função de pertinência para a interseção é :

$$f_{A \cap B}(x) = f_C(x) = \min(f_A(x), f_B(x)) = \wedge(f_A(x), f_B(x))$$

onde \wedge significa "o menor dos argumentos".

Os operadores \wedge e \vee (min e máx) satisfazem às seguintes exigências :

i) O valor da função de pertinência de x em um conjunto fuzzy composto, depende unicamente das funções de pertinência dos conjuntos elementares em x que o originaram, para todo $x \in X$.

ii) Tanto o operador \vee como \wedge , aplicados em dois conjuntos fuzzy, são comutativos, associativos e mutuamente distributivos.

iii) \vee e \wedge são contínuos e não decrescentes com relação a cada um de seus argumentos.

iv) Os operadores $\vee(a, a)$ e $\wedge(a, a)$ são rigidamente crescentes em relação a (a) .

- v) Pertinência em A ou B implica pertinência em $A \cup B$.
- vi) Completa falta de pertinência em A ou B implica completa falta de pertinência em $A \cup B$.

Estas são algumas propriedades das operações em conjuntos fuzzy. Suas correspondentes demonstrações, bem como outras definições complementares, podem ser encontradas em Pal e Dwijesh [1986] e Kandel [1979,1986], as quais não serão detalhadas no presente estudo.

A abordagem de Rosenfeld et alii. propõe a seguinte regra para o processo fuzzy :

$$p_i^{t+1}(h) = \bigwedge_{j=0}^B \bigvee_{k=0}^m r_j(h,k) p_j^t(k)$$

A aproximação dos coeficientes de compatibilidade, proposta no processo estatístico, falha neste caso devido a que $r_j(h,k)$ não está definido para $j=0$. Para superar esta deficiência, adota-se a definição para $j=0$:

$$r_j(h,k) = \delta(h,k) \text{ ou seja,}$$

$$r_j(h,k) = 0 \quad \text{se } h \neq k$$

$$r_j(h,k) = 1 \quad \text{se } h = k$$

com o que a equação fuzzy proposta por Rosenfeld et alii. é alterada:

$$p_i^{t+1}(h) = \bigwedge_{j=1}^B \left(p_i^t(h) \bigwedge \bigvee_{k=0}^m r_j(h,k) p_j^t(k) \right)$$

O esquema seguinte pode servir para entender a anterior equação:

$$p_i^{t+1}(h) = \bigwedge_{j=1}^B \left(p_i^t(h) \bigwedge \underbrace{\bigvee_{k=0}^m r_j(h,k) p_j^t(k)}_{(a)} \right)_{(b)}_{(c)}$$

- a) Escolhe-se o maior valor de $r_j(h,k)p_j^t(k)$ entre as possíveis

classes para a posição "j" da janela.

b) O valor resultante de (a) é comparado com o valor do pixel central na posição "i" e o menor entre estes dois é escolhido.

c) A partir dos valores obtidos em (b) para cada posição na janela, o menor valor é selecionado.

Tendo notado a baixa eficiência deste processo em relação ao probabilístico, quando se considera a relação entre pares de indivíduos, Di Zenzo et alii. [1989] propõem uma variação dele que não mais considera um pixel isolado por vez, se não um grupo deles na forma de uma sub-vizinhança. Para isto, definem o conjunto de valores possíveis da função de pertinência fuzzy da forma :

$$f(K) = K/d \quad \text{para } K=0,1,2,\dots,d$$

onde d é uma constante e deve ser o maior possível, em função das limitações computacionais, a fim de garantir uma boa discriminação entre os valores de f(K)

$$f(K) \in \mathcal{F}(d) = (0 , 1/d , 2/d , 3/d , \dots [d-1]/d , 1)$$

É necessário ainda a introdução de uma variante dos operadores \bigvee e \bigwedge . Para todo a,b em $\mathcal{F}(d)$ e cada $\tau = 0,1,2,\dots,d$:

$$a \bigvee_{\tau} b = \begin{cases} a \bigwedge b & \text{se } a,b \geq f(\tau) \text{ ou } a,b < f(\tau) \\ a \bigvee b & \text{caso contrário} \end{cases}$$

$$a \bigwedge_{\tau} b = \begin{cases} a \bigvee b & \text{se } a,b \geq f(\tau) \text{ ou } a,b < f(\tau) \\ a \bigwedge b & \text{caso contrário} \end{cases}$$

O papel de τ nestas definições é o de fixar um limiar $f(\tau)$.

Note-se que $a \bigvee_{\tau} b$ fica acima do limiar se, e somente se, a ou b (ou ambos) estão acima deste limiar; $a \bigwedge_{\tau} b$ está acima do limiar se, e somente se, ambos(a e b) estão acima de $f(\tau)$. Assim sendo, \bigvee_{τ} e \bigwedge_{τ}

têm a natureza de um ou e um e lógico respectivamente, ambos controlados pelo valor do limiar $f(\tau)$. Com estes conceitos, Di Zenzo et alii. [1989] alteram a formulação fuzzy para :

$$p_i^{t+1}(h) = \bigwedge_{j=1}^B \left\{ p_i^t(h) \wedge_{\tau} \bigwedge_{l=j}^{j+q} \bigvee_{\theta} r_l(h,k) p_l^t(k) \right\}$$

onde uma sub-vizinhança inteira (1), composta do pixel i junto com q vizinhos consecutivos, é considerada em lugar de um vizinho isolado.

O baixo desempenho desta abordagem foi verificado por Di Zenzo et alii. [1989] que sugere a adoção de outra forma dos coeficientes de compatibilidade para compensar as deficiências. Esta modificação será também adotada no presente estudo. O coeficiente de compatibilidade para a relaxação fuzzy não é estimado a partir da imagem temática resultante do processo de classificação espectral, mas é uma simplificação da forma:

$$\begin{aligned} r_j(h,k) &= 1 \text{ se } h=k \\ r_j(h,k) &= 0 \text{ se } h \neq k \end{aligned}$$

Com isto pretende-se favorecer a co-ocorrência de pixels com a mesma classe em posições adjacentes e um efeito de homogeneização será dado em áreas ocupadas por uma única classe. Este processo remove os pixels de classes diferentes sem levar em consideração a relação contextual entre classes diferentes e baseando-se unicamente na alta correlação entre pixels de mesma classe. Com esta simplificação:

$$p_i^{t+1}(h) = \bigwedge_{j=1}^B \left\{ p_i^t(h) \wedge_{\tau} \bigwedge_{l=j}^{j+q} p_l^t(h) \right\}$$

Utilizando novamente um esquema, pode-se facilitar a compreensão da formulação.

$$p_i^{l+1}(h) = \bigwedge_{j=1}^B \left\{ p_i^l(h) \bigwedge_{\tau} \underbrace{\bigwedge_{l=j}^{j+q} p_l^l(h)}_{(a)} \right\}$$

(b)
(c)

a) Nesta operação, o menor valor da função de pertinência, em relação ao limiar θ , é escolhido dentro de uma sub-vizinhança de "q+1" pixels em torno do pixel central "i". Devido à simplificação do coeficiente de compatibilidade introduzida anteriormente, unicamente a classe "h" igual à classe do pixel central é pesquisada.

b) O Segundo operador seleciona o menor valor em relação a τ entre o valor resultante de (a) e o valor do pixel central associado à classe "h".

c) Finalmente, o terceiro operador seleciona o menor valor entre os obtidos na operação anterior para cada uma das sub-vizinhanças definidas por "q" e "l".

O operador \bigwedge_{θ} considerado na subvizinhança (q+1) tem a particularidade de escolher a maior função de pertinência de $p_j(h)$ se as funções de pertinência na sub-vizinhança forem todas superiores ou todas inferiores ao limiar θ . Na situação em que pelo menos uma função de pertinência inferior ao limiar, o menor valor é escolhido.

3.3.6. Processo de Relaxação Fuzzy Modificado com a Média Local

Uma segunda tentativa orientada a utilizar a informação de uma sub-vizinhança similar à anterior, baseada no valor médio desta sub-vizinhança, é testada. Devido à natureza aleatória das observações (\underline{x}) é possível encontrar pixels com valores extremamente baixos na vizinhança do pixel central. Valores muito baixos para uma classe implicam valores maiores para as outras ou pelo menos uma das outras. Se numa circunstância determinada existirem dois pixels adjacentes,

com valor baixo para a classe "B" e alto para uma segunda classe "A", dentro de uma região onde as probabilidades dos pixels são altas para a classe "B", pode-se dizer que ambos estejam mal classificados. Dependendo da situação estes pixels mal classificados podem se sustentar mutuamente, pois um corresponde à vizinhança do outro e, o que é pior ainda, propagar este erro para os pixels imediatamente próximos. O fato do processo fuzzy ser um processo que unicamente diminui o valor das probabilidades para cada pixel pode levar à introdução de erros os quais não podem ser detectados pelo próprio processo e que se propagam na medida em que são os menores valores da região. Esta dificuldade já era apontada por Rosenfeld et alii. [1976] quem fazia notar que em processos fuzzy de relaxação os valores baixos são "contagiosos" e que neles tem-se notado um desempenho menor em relação aos do tipo probabilístico.

Com a finalidade de superar esta deficiência substitui-se um dos operadores fuzzy introduzido por Di Zenzo et alii. [1989] pelo valor médio da sub-vizinhança. Com isto pretende-se filtrar as ocorrências de vizinhos com valor de probabilidade extremamente baixo quando o valor do resto da vizinhança é alto, que de outra maneira determinaria um valor baixo para o pixel central. Assim a abordagem fuzzy adota a forma:

$$p_i^{t+1}(h) = \bigwedge_{j=1}^8 \left\{ p_i^t(h) \bigwedge_{r} \text{med}_{l=j}^{j+q} \bigvee_{k=0}^m r_l(h,k) p_l^t(k) \right\}$$

Desta forma, quando a sub-vizinhança tiver dois ou mais valores muito baixos o seu valor médio será baixo e passará influenciar o valor central. Caso contrário, se unicamente um valor for muito pequeno, o uso do valor médio ameniza o seu efeito no valor do pixel central.

Com a simplificação do coeficiente de compatibilidade, a abordagem fuzzy com a introdução da média da sub-vizinhança em lugar do limiar θ pode-se escrever:

$$P_i^{t+1}(h) = \bigwedge_{j=1}^B \left\{ P_i^t(h) \bigwedge_{\tau} \text{med}_{l=j}^{j+q} (P_l^t(h)) \right\}$$

$$P_i^{t+1}(h) = \bigwedge_{j=1}^B \left\{ P_i^t(h) \bigwedge_{\tau} \frac{1}{q+1} \sum_{l=j}^{j+q} P_l^t(h) \right\}$$

Novamente, um esquema pode ser útil para entender a formulação do algoritmo:

$$P_i^{t+1}(h) = \bigwedge_{j=1}^B \left\{ \underbrace{P_i^t(h) \bigwedge_{\tau} \underbrace{\frac{1}{q+1} \sum_{l=j}^{j+q} P_l^t(h)}_a}_{b} \right\}_c$$

(a) Nesta primeira operação, o valor médio da sub-vizinhança definida por "j" e "q" é calculado. Desta forma pretende-se diminuir a influência de um único valor baixo dentro da vizinhança de "i".

b) O segundo operador seleciona o menor valor em relação a τ entre o valor resultante de (a) e o valor do pixel central associado à classe "h".

c) Finalmente, o terceiro operador seleciona o menor valor entre os obtidos na operação anterior para cada uma das sub-vizinhanças definidas por "q" e "l".

3.3.7. Processo de Filtragem Espacial Combinado com a Relaxação Probabilística

Uma finalidade do processo de classificação contextual é corrigir a classificação daqueles pixels cuja classe atribuída é diferente da classe atribuída a sua vizinhança. Devido a estes erros estarem relacionadas aos valores das probabilidades que relacionam cada pixels

da vizinhança com as classes, a alteração destas probabilidades ocasiona mudanças na imagem temática produzida. A seguir será introduzido um método alternativo que pretende acelerar o processo de classificação contextual. Para isto são necessárias algumas simplificações nas hipóteses adotadas.

Em cenas naturais de áreas extensas cobertas por vegetação as diferenças nos valores das probabilidades $p_i(h)$ podem estar relacionadas a fatores alheios à natureza ou estado da vegetação, como ser a sombra de uma planta projetada sobre a outra devido à diferença de altura entre ambas. No entanto esta diferença também pode ser causada por diferença na resposta de fundo ou presença de outros alvos misturados no pixel.

Se a imagem estudada apresentar predominantemente áreas homogêneas, com um número pequeno de pixels pertencentes a outras classes, haveria maior probabilidade de co-ocorrência de pixels pertencentes a uma mesma classe na imagem, pois os valores das probabilidades também seriam homogêneos. Assim a probabilidade da ocorrência da mesma classe dentro da janela móvel é reforçada. Para fins deste estudo supõe-se a ausência destes pixels misturados.

Dentro desta simplificação a distribuição espacial das classes tenderia a formar grupos e diminuiria a probabilidade de ocorrerem pixels de classes diferentes dentro delas pelo que se "i" e "j" estão situados em posições próximas dentro da imagem, então $p_i(h)$ e $p_j(h)$ tenderiam a ter valores próximos. Da mesma forma a probabilidade de $p(ieh, jek)$ para $h \neq k$ torna-se muito pequena e $p(ieh, jeh)$ se aproxima de $p(ieh)$. Por meio desta simplificação o valor de compatibilidade pode ser escrito da forma:

$$r_j(h,k) = 1 \text{ se } h=k$$
$$r_j(h,k) = 0 \text{ se } h \neq k$$

Assim, se elimina o somatório para classes diferentes de "h" e o

processo de relaxação pode ser escrito:

$$p_i^{l+1}(h) = \sum_{j=0}^8 d_{ij} p_j^l(h)$$

que corresponde à forma matemática do processo de filtragem espacial. Existe uma grande variedade de filtros que podem ser utilizados dentro desta definição, conforme os valores adotados para d_{ij} . Em outras palavras, pode-se construir o filtro desejado escolhendo-se valores adequados para d_{ij} . Como a intenção do processo é homogeneizar a imagem temático dentro das áreas homogêneas, o filtro usado é do tipo passa-baixas. Valores maiores de d_{ij} podem ser atribuídos aos vizinhos mais próximos de "i" em função da distância menor que os separa do pixel central.

3.4. Imagem Sintética

A exatidão dos processos acima propostos pode ser avaliada através da utilização de áreas teste. Neste caso, o resultado da classificação é comparado com os dados conhecidos dessas áreas, que podem ser obtidos por meio de fotografias aéreas ou diretamente por verificação local. Uma maneira alternativa de testar o desempenho do classificador é mediante o uso de uma imagem sintética. Em uma imagem sintética o número digital (ou reflectância) correspondente a cada banda é gerado segundo uma função densidade de probabilidade previamente escolhida. A distribuição espacial das classes é pré-fixada pelo que a classe associada a cada pixel torna-se conhecida.

Com a finalidade de testar o desempenho do classificador pela Máxima Verossimilhança e o processo contextual foram geradas cenas sintéticas em três bandas. Para realizar esta tarefa foi elaborado o programa SINTET que, alimentado da informação a respeito dos parâmetros da distribuição de cada classe, gera um conjunto de três bandas com valores de número digital que obedecem a uma distribuição normal.

A geração de uma variável aleatória segundo uma distribuição normal pode ser obtida a partir de uma distribuição retangular, que geralmente consta na biblioteca dos vários compiladores, e fazendo uso do teorema do limite central :

Seja "U" uma variável aleatória com distribuição retangular entre zero e um,

$$0 \leq u \leq 1$$

$$\mu = E(u) = 0.5$$

$$\begin{aligned} \sigma = \text{var}(u) &= \int_0^1 (u - 0.5)^2 du = \int_0^1 (u^2 - u + 0.25) du = \\ &= [1/3 u^3 - 1/2 u^2 + 1/4 u]_0^1 = [1/3 - 1/2 + 1/4] = 1/12 \end{aligned}$$

Pelo teorema do limite central se X é a soma de um conjunto de "n" variáveis aleatórias identicamente distribuidas, então a distribuição de X tende a uma distribuição normal na medida em que "n" cresce ($n \rightarrow \infty$).

Considando a variável

$$X = U_1 + U_2 + U_3 + U_4 + \dots + U_{n-1} + U_n$$

As variáveis U_1, U_2, \dots, U_n são variáveis aleatórias, independentes e todas obedecem a distribuição acima descrita com média $\mu=0.5$ e variância $\sigma^2=1/12$.

Pelo teorema do limite central sabe-se que, se "n" é grande então a distribuição de X é aproximadamente normal, com média $\mu_x = n * \mu$ e variância $\sigma_x^2 = n * \sigma^2$. No caso presente $\mu_x = n * 0.5$ e $\sigma_x^2 = n/12$.

A padronização (média igual a zero e variância unitária) pode ser obtida escolhendo o valor de "n" que satisfaz:

$$\sigma_x^2 = n/12 = 1$$

segue-se que

$$n=12$$

e para a média

$$X = U_1 + U_2 + U_3 + \dots + U_{12} - 6$$

$$\mu_x = \sum_{i=1}^{12} E(U_i) - 6 = 12 \times 0.5 - 6 = 0$$

Portanto a variável aleatória :

$$X = U_1 + U_2 + U_3 + \dots + U_{12} - 6$$

apresenta uma distribuição normal padronizada ($\mu_x=0$, $\sigma_x^2=1$)

A partir da geração de números aleatórios da biblioteca do compilador obtem-se, segundo a operação descrita, a variável X com distribuição N(0,1).

A função "cálculo de parâmetros estatísticos" do sistema SITIM-150 fornece os parâmetros da distribuição de alvos escolhidos na imagem. Sejam $m(A)$ a média da classe em uma banda escolhida e $\text{var}(A)$ a sua variância, adotando $B = (\text{var}(A))^{1/2} * x + m(A)$, obtem-se a distribuição :

$$\begin{aligned} E[B] &= E[(\text{var}(A))^{1/2} * x] + E[m(A)] = (\text{var}(A))^{1/2} * E[x] + m(A) \\ &= (\text{var}(A))^{1/2} * 0 + m(A) = m(A) \end{aligned}$$

$$\begin{aligned} \text{var}(B) &= ((\text{var}(A))^{1/2})^2 * \text{var}(X) + \text{var}(m(A)) \\ &= \text{var}(A) * 1 + 0 = \text{var}(A) \end{aligned}$$

Desta maneira é possível gerar uma distribuição similar à da classe de interesse em cada banda. Neste processo não se leva em consideração a covariância entre duas bandas para a classe, pelo que os eixos da distribuição são gerados paralelos aos eixos coordenados.

A introdução das covariâncias, isto é, dos elementos fora da diagonal presentes na matriz de covariância das classes amostradas, pode ser realizada fazendo uso das propriedades dos autovetores e autovalores da matriz presentes na transformação de Hotelling ou Karhunen-Loève, baseada nas propriedades estatísticas dos elementos de cada classe e utilizada geralmente na rotação ou compressão de dados (Gonzales e Wintz 1977).

O procedimento pode ser descrito da seguinte maneira. Seja \underline{A} uma matriz quadrada de dimensão $(p \times p)$ e \underline{I} a matriz identidade de mesma dimensão. Os escalares $\lambda_1, \lambda_2, \dots, \lambda_p$ que satisfazem a equação $|\underline{A} - \lambda \underline{I}| = 0$ são chamados de autovalores (ou raízes características) da matriz \underline{A} . A equação $|\underline{A} - \lambda \underline{I}| = 0$ (como função de λ) é chamada de equação característica. Os autovetores da matriz \underline{A} associados a λ são aqueles vetores não nulos que satisfazem a relação :

$$\underline{A} \underline{e} = \lambda \underline{e}$$

É assumido, por conveniência, que os autovalores estão ordenados de forma decrescente, assim $\lambda_1 > \lambda_2 > \dots > \lambda_p$. A matriz $p \times p$ cujas colunas são constituídas pelos autovetores de \underline{A} é a responsável pela transformação de Hotelling e que será denotada por \underline{B} .

$$\underline{B} = \begin{pmatrix} e_{11} & e_{12} & \dots & e_{1p} \\ e_{21} & e_{22} & \dots & e_{2p} \\ \vdots & & \dots & \\ e_{p1} & e_{p2} & \dots & e_{pp} \end{pmatrix}$$

Onde e_{ij} é a j -ésima componente do i -ésimo autovetor.

Existem várias combinações possíveis para \underline{e} pelo que geralmente se adotam os autovetores normalizados.

A transformação de Hotelling consiste em multiplicar os vetores

que correspondem a uma imagem centralizada em \underline{m} , isto é, os vetores $(\underline{x}-\underline{m})$, pela matriz \underline{B} obtida a partir dos autovetores e autovalores da matriz de covariância da imagem, ou seja:

$$\underline{y} = \underline{B} (\underline{x} - \underline{m}_x)$$

Uma das propriedades desta transformação é que a variável resultante (\underline{y}) possui média igual a zero, o que pode ser demonstrado da seguinte maneira:

$$\begin{aligned} \underline{m}_y &= E[\underline{y}] \\ &= E[\underline{B}(\underline{x} - \underline{m}_x)] \\ &= \underline{B} E[\underline{x}] - \underline{B} \underline{m}_x = 0 \end{aligned}$$

Da mesma forma se mostra que a a matriz de covariância de \underline{y} assume a seguinte forma:

$$\begin{aligned} \text{cova}(\underline{y}) &= E\left((\underline{B} \underline{x} - \underline{B} \underline{m}_x) (\underline{B} \underline{x} - \underline{B} \underline{m}_x)' \right) \\ \text{cova}(\underline{y}) &= E\left(\underline{B}(\underline{x} - \underline{m}_x) (\underline{x} - \underline{m}_x)' \underline{B}' \right) \\ \text{cova}(\underline{y}) &= \underline{B} E\left((\underline{x} - \underline{m}_x) (\underline{x} - \underline{m}_x)' \right) \underline{B}' \\ \text{cova}(\underline{y}) &= \underline{B} \text{cova}(\underline{x}) \underline{B}' \end{aligned}$$

Pode ser demonstrado (Johnson et alii. 1982) que a matriz de covariância de \underline{y} é a matriz diagonal com elementos iguais aos autovalores, ou seja:

$$\text{cova}(\underline{y}) = \begin{pmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & & & \\ 0 & & & 0 \\ 0 & 0 & \dots & \lambda_p \end{pmatrix}$$

A importância desta última propriedade é que a transformação de Hotelling resulta em novas variáveis (\underline{y}) cuja matrizes de covariância possuem os elementos fora da diagonal nulos, o que significa que os elementos de \underline{y} são não correlacionados. Além disso, cada autovalor λ_i

corresponde à variância do i -ésimo elemento de \underline{y} na direção do vetor característico e_i .

Uma outra propriedade é que se torna possível reconstituir \underline{x} a partir de \underline{y} . já que $\text{cova}(\underline{x})$ é uma matriz real e simétrica é sempre possível encontrar um conjunto de autovetores ortonormais. Com isso $\underline{B}^{-1} = \underline{B}'$ e \underline{x} pode ser obtido usando :

$$\underline{x} = \underline{B}' \underline{y} + \underline{m}_x$$

Desta última relação se conclui que pode-se gerar um conjunto de pixels \underline{x} cuja matriz de covariância apresenta elementos não nulos fora da diagonal principal a partir de uma população que apresenta correlação nula entre as variáveis (no caso presente, bandas espectrais). Para isto, gera-se uma população com distribuição normal no espaço de (y) , cuja matriz de covariância tenha elementos fora da diagonal principal iguais a zero e onde os elementos na diagonal principal, as variâncias, correspondem aos autovalores da matriz de covariância da distribuição desejada ($\text{cova}(\underline{x})$). O seguinte passo é aplicar a rotação mediante a inversa da transformação de Hotelling, multiplicando os vetores gerados (\underline{y}) pela matriz composta pelos autovetores da distribuição procurada. O último passo é posicionar a distribuição em relação ao vetor de médias de \underline{x} .

3.5. Critérios de Medida de Convergência e Precisão

Devido à natureza iterativa dos processos de relaxação acima descritos, faz-se necessário um parâmetro que informe a respeito da taxa de convergência do processo. Para tal finalidade podemos utilizar as seguintes medidas :

A primeira é a taxa média de variação nos valores das probabilidades de pertinência das classes:

$$R(t) = (1/N) \sum_{h=0}^m \sum_{i=1}^N | p_i^t(h) - p_i^{t-1}(h) |$$

N = número total de pixels classificados na iteração t.

A segunda é a entropia definida por:

$$H(t) = - \frac{1}{N} \sum_{i=1}^N \sum_{h=0}^m p_i^t(h) \ln(p_i^t(h))$$

H(t) representa a incerteza residual da classificação por pixel após t iterações e pode ser entendida como o grau de desordem do conjunto de probabilidades $p_i^t(h)$.

Uma condição necessária para qualquer ajuste iterativo das probabilidades de pertinência das classes ter significado é que, tanto R(t) como H(t), sejam monotonicamente decrescentes com t (Di Zenzo et alii, 1989).

A avaliação da precisão da classificação pode ser monitorada, nestes processos de relaxação, mediante a análise da matriz de confusão das classes de estudo.

A matriz de confusão pode ser obtida para situações onde a verdade terrestre é totalmente conhecida. Isto implica o conhecimento da verdadeira classificação de cada um dos pixels na imagem, ou pelo menos na área que vai ser classificada. Como na prática essa informação é difícil de obter, devido ao tamanho da área e o elevado custo de seu levantamento, tal avaliação não poderá ser utilizada em imagens reais, ficando a análise da matriz de confusão restrita a imagens sintéticas onde a classificação correta é conhecida.

No caso de imagens reais a avaliação deverá se restringir à análise da classificação de certas sub-regiões da imagem as quais são conhecidas através de fotografias aéreas oblíquas. O número de fotografias úteis e disponíveis é um fator limitante do número de

pontos que podem ser monitorados, quanto a sua classificação ao longo dos processos iterativos. Uma outra forma de verificar o funcionamento dos processos de relaxação é pela análise puramente visual da imagem resultante produzida, levando em consideração o grau de homogeneização das áreas ocupadas pelas classes, a definição de suas fronteiras e a classificação espectral visual a partir da imagem multiespectral e das fotografias aéreas.

Segundo Eklundh (1980), o processo de relaxação terminaria quando um valor mínimo para o erro da classificação for alcançado. Como a determinação do erro cometido exige o conhecimento da classificação correta de cada pixel, isto se torna inviável em imagens naturais. Para superar esta deficiência Eklundh et alii. [1980] sugere que o ponto que marcaria o final do processo iterativo pode ser obtido a partir da evolução do valor da taxa média de variação.

IV EXPERIMENTOS

4.1 Descrição das Imagens

Os algoritmos de classificação contextual foram implementados em programas para computador de maneira a serem utilizados no sistema de tratamento de imagem Sitim-150, disponível no Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia da UFRGS. Os programas foram elaborados na linguagem C e utilizaram as bibliotecas e rotinas próprias do sistema Sitim-150. Após sua implementação, tais algoritmos foram submetidos a uma série de testes para avaliar sua contribuição à precisão da classificação da imagem. Os testes foram realizados em imagens sintéticas, elaboradas para essa finalidade, bem como em cenas reais da série Landsat-TM.

4.1.1. Imagem Sintética

Foi inicialmente gerada uma imagem sintética multiespectral, formada por três bandas. Assumiu-se que a função densidade de probabilidade para cada classe segue uma distribuição normal. Desta forma, cada classe fica descrita pelo seu vetor de médias (\underline{m}_h) e sua matriz de covariância (Σ_h). A variação desses parâmetros populacionais, permite simular situações diversas, com relação à separabilidade das classes simuladas, no espaço multiespectral.

Os parâmetros da distribuição das classes para a imagem sintética foram obtidos a partir da distribuição de alvos reais em uma imagem LANDSAT-TM, correspondente à bacia do rio Potiribú, no Estado do Rio Grande do Sul. As bandas utilizadas foram as TM-3, TM-4 e TM-5.

Um programa de computador, denominado LENC3 (Leitura de Nível de Cinza em 3 bandas) foi desenvolvido com a finalidade de obter amostras na imagem em um formato passível de ser utilizado em algum pacote (software) estatístico para determinar os parâmetros da população. Neste caso foi utilizado o MINITAB. Operando-se diretamente o cursor disponível na unidade visualizadora de imagens (UVI) do sistema

Sitim-150, áreas de amostragem para as diversas classes de interesse foram delimitadas. O programa LENC3 realiza a leitura dos números digitais de cada pixel destas áreas e os armazena na forma de números inteiros em um arquivo seqüencial no disco rígido, em três colunas, uma para cada banda lida. Assim, para cada classe, são tomadas amostras, nas bandas espectrais de interesse. Os parâmetros estatísticos necessários (vetor de médias e matriz de covariância) podem então ser estimados.

Na geração da imagem sintética, foram selecionadas classes situadas próximas entre si no espaço multiespectral (o que ocorre com freqüência em cenas reais). Neste caso, o processo de classificação, utilizando exclusivamente atributos espectrais, resulta em um certo número de pixels mal classificados. A eficiência dos atributos de contexto no processo de classificação pode então ser testada.

Da mesma forma tomou-se o devido cuidado para não gerar classes com demasiada diferença quanto à variância pois, em função do critério adotado para a rejeição no processo de classificação espectral. Quando uma classe tem variância exageradamente pequena em relação às outras classes, o valor da sua função discriminante na fronteira do elipsoide de confiabilidade gerado pela estatística de Hotelling é muito maior do que aquele correspondente à classe com maior variância e pode resultar na inclusão das classes com menor variância na classe de rejeição denominada "fundo", como é mostrado na figura 3.3 e comentado no item 3.3.2.

4.1.1.1. Entradas do Programa SINTET para Geração da Imagem Sintética

O programa SINTET segue a metodologia descrita para geração de imagens sintéticas a partir do vetor de médias, autovalores e a matriz de autovetores para cada classe.

A distribuição espacial dos pixels é feita segundo o critério da distância mínima em relação a centros pré-determinados. Cada um destes

centros é considerado como pertencente a uma classe e aqueles pixels que ficarem mais próximos a ele são atribuídos à mesma classe. Assim, os passos a ser seguidos pelo programa são:

- Cálculo a distância entre a posição do pixel a ser gerado na imagem e cada um dos centros.

- Atribui-se o pixel à mesma classe do centro cuja distância seja a menor entre as distâncias calculadas no passo anterior.

Os centros são atribuídos às classes em forma crescente de ordem de entrada, isto é, o primeiro centro corresponde à classe 0, o segundo à 1, etc, até superar o número de classes (m), quando novamente se atribui os pixels às classes 0,1,2...m.

- Geração da resposta espectral sintética a partir dos parâmetros estatísticos da classe escolhida, conforme descrito no item 3.4.

Esta metodologia permite construir imagens sintéticas, nas quais as diferentes classes presentes apresentam uma distribuição espacial bem conformada, onde o classificador contextual possa atuar corrigindo os prováveis erros gerados na classificação que utiliza unicamente atributos espectrais.

Os dados de entrada devem estar contidos no arquivo SINTET.J, em código ASCII, e obedecer o seguinte formato e ordem :

NOME DA IMAGEM GERADA	(3 caracteres)
NUMERO DE BANDAS	(um inteiro)
NUMERO DE CLASSES	(um inteiro)

A seguir devem constar, segundo o número de classes e bandas geradas as seguintes informações para cada classe:

Médias e autovalores;

MEDIA DA BANDA 1	(um inteiro)
MAIOR AUTOVALOR	(um valor de ponto flutuante - float)
MEDIA DA BANDA 2	(um inteiro)
2do MAIOR AUTOVALOR	(um valor de ponto flutuante - float)
.....	
MEDIA DA BANDA i	(um inteiro)
i-éssimo MAIOR AUTOVALOR	(um valor de ponto flutuante - float)

matriz de autovetores "e_{i,j}";

e ₁₁	e ₁₂	e ₁₃	e ₁₄	...	e _{1i}
e ₂₁	e ₂₂	e ₂₃	e ₂₄	...	e _{2i}
.....				
e _{i1}	e _{i2}	e _{i3}	e _{i4}	...	e _{ii}

(Valores de ponto flutuante.)

Distribuição espacial;

NUMERO DE CENTROS	(um inteiro = n)
COORDENADA X DE IMAGEM DO CENTRO 1	(um inteiro)
COORDENADA Y DE IMAGEM DO CENTRO 1	(um inteiro)
COORDENADA X DE IMAGEM DO CENTRO 2	(um inteiro)
COORDENADA Y DE IMAGEM DO CENTRO 2	(um inteiro)
...	...
COORDENADA X DE IMAGEM DO CENTRO n	(um inteiro)
COORDENADA Y DE IMAGEM DO CENTRO n	(um inteiro)

Dimensão da imagem

NUMERO DE LINHAS	(um inteiro)
NUMERO DE COLUNAS	(um inteiro)

4.1.1.2. Imagens Geradas

A primeira imagem gerada obedece aos seguintes parâmetros no arquivo SINTET.J , conforme descrito anteriormente:

SIC	
3	3
71	30.9209
50	15.4672
29	5.9844
.939448	.300588 .162218
-.193044	.859382 -.473698
.282486	-.413801 -.864925
62	68.82
72	24.50
25	13.157
.197334	.948598 -.246581
.973224	-.158660 .166626
-.119148	.273089 .954207
53	34.757
55	6.081
25	3.7
.42008	.905657 -.051388
.903357	-.423449 -.065322
.080383	.01872 .996122
12	
5	10
9	22
7	42

20	9
18	17
17	35
27	5
28	17
25	25
33	9
35	15
43	37
50	50

O que corresponde a uma imagem com nome "SIC" com 3 bandas (b1,b2,b3) e três classes. A imagem possui 50 linhas e 50 colunas. A distribuição espacial das classes é tal que elas se encontram agrupadas dividindo a área em três regiões verticais.

A segunda imagem está descrita no arquivo SINTET.J da seguinte maneira :

```

SIE
3      3
71      30.9209
50      15.4672
29      5.9844
.939448 .300588 .162218
-.193044 .859382 -.473698
.282486 -.413801 -.864925
62      68.82
72      24.50
25      13.157
.197334 .948598 -.246581
.973224 -.158660 .166626
-.119148 .273089 .954207
53      34.757
55      6.081
25      3.7
.42008 .905657 -.051388
.903357 -.423449 -.065322
.080383 .01872 .996122
12
17 35
27 5
28 17
25 5
10 9
22 7
42 20
9 18
17 25
33 9

```

35 15
43 37
50 50

As classes presentes nesta imagem possuem as mesmas características da imagem SIC. A diferença básica entre as duas é a distribuição espacial das classes. Na imagem SIE as classes formam 9 áreas em lugar de três. Com isto se pretende alterar os coeficientes de compatibilidade e aumentar as fronteiras entre classes. A imagem tem 50 linhas e 50 colunas e possui 3 classes e 12 centros.

Um esboço da posição das classes no espaço multiespectral pode ser visto na figura 4.1. A figura 4.2 mostra a distribuição espacial das classes nas imagens SIC e SIE geradas.

4.1.2. Imagens reais

O teste dos algoritmos em imagens reais foi realizado utilizando a imagem de uma área onde presentemente são desenvolvidas outras pesquisas pelo Instituto de Pesquisas Hidráulicas da UFRGS (IPH), dentro de um convênio de cooperação internacional (CNPq-ORSTOM). Nessa região foram selecionadas pequenas áreas para fins de teste.

A bacia do rio Potiribú está situada no Planalto médio do Estado do Rio Grande do Sul e enfrenta problemas sérios de erosão devido a inadequadas práticas agrícolas. Dentro desta bacia foi escolhida uma sub-bacia representativa (Bordas 1988), a bacia do Arroio Taboão, de aproximadamente 100 Km^2 de área, localizada entre as latitudes $s-28^{\circ}22'$ e $s-28^{\circ}30'$ e as longitudes $o-53^{\circ}53'$ e $o-53^{\circ}51'$. Os dados escolhidos para testar o algoritmo proposto nesta bacia consistem das bandas Landsat TM 3,4 e 5, obtidas no mês de abril de 1989, órbita 223.80, quadrante B.

Três dias antes da passagem do satélite foi realizado um voo de baixa altitude que possibilitou a obtenção de fotografias oblíquas preto e branco e coloridas. Este material foi utilizado para obter a

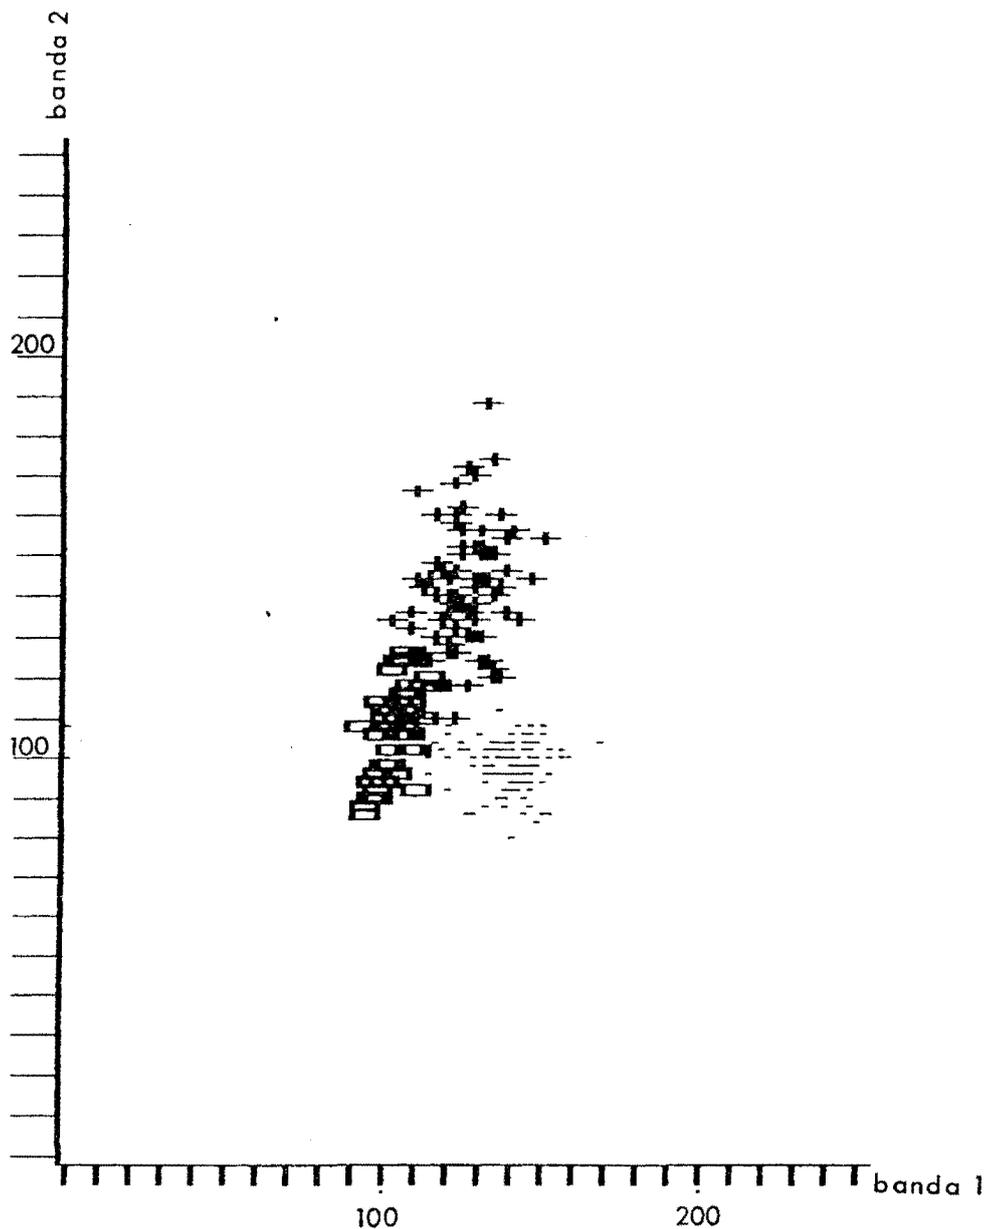


FIGURA 4.1.a.: Representação gráfica da distribuição espectral das classes geradas para a imagem sintética. Os valores do contador digital foram gerados a partir da estimativa dos parâmetros média e variância de uma imagem LANDSAT TM real da bacia do arroio Potiribú. A banda 1 corresponde à banda TM-3 e a banda 2 corresponde à banda TM-4.

Legenda:

Classe 1	_____	.
Classe 2	_____	+
Classe 3	_____	□

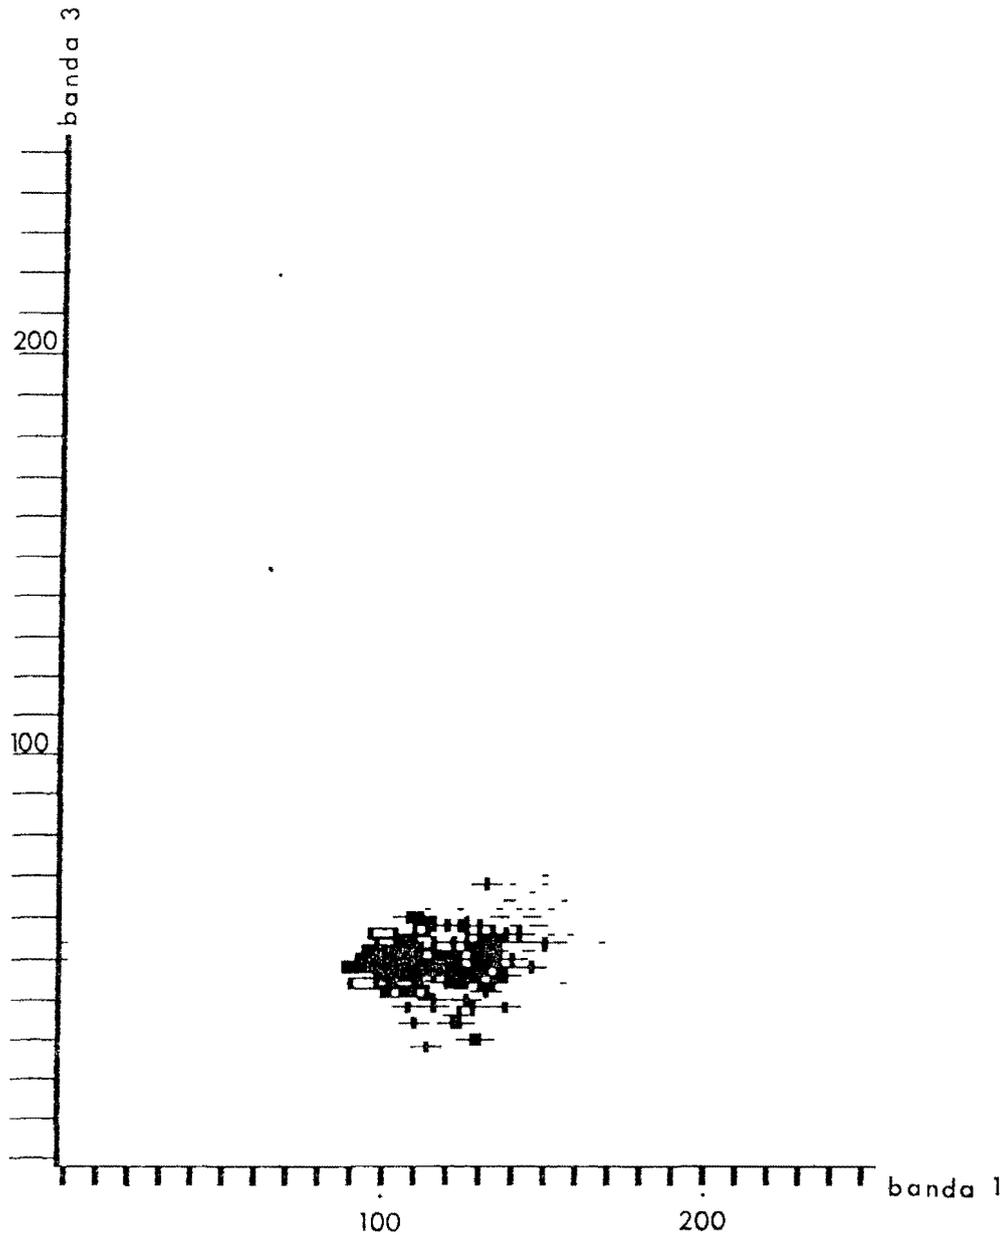


FIGURA 4.1.b.: Representação gráfica da distribuição espectral das classes geradas para a imagem sintética. Os valores do contador digital foram gerados a partir da estimativa dos parâmetros média e variância de uma imagem LANDSAT TM real da bacia do arroio Potiribú. A banda 1 corresponde à banda TM-3 e a banda 3 corresponde à banda TM-5.

Legenda: Classe 1 _____ .
 Classe 2 _____ +
 Classe 3 _____ □

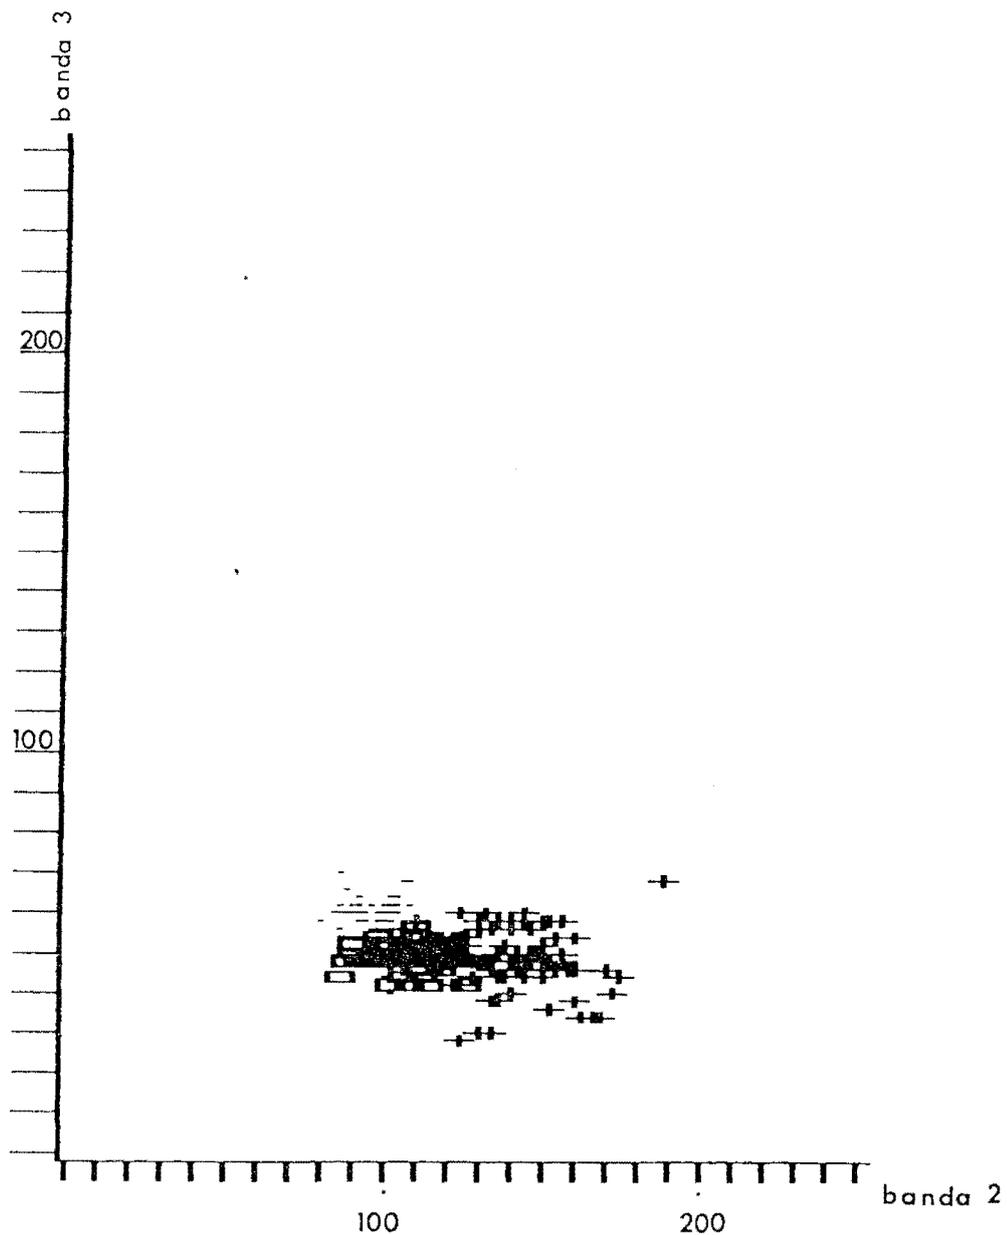
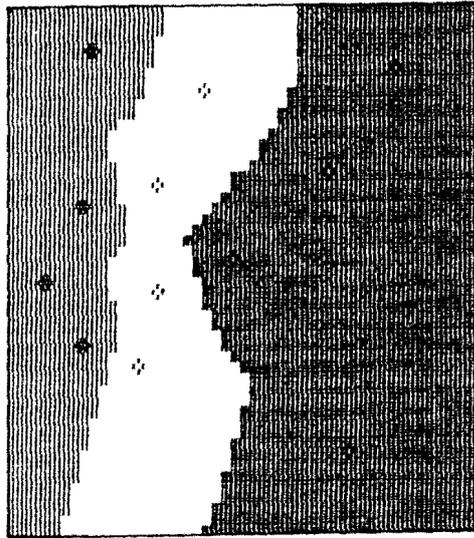
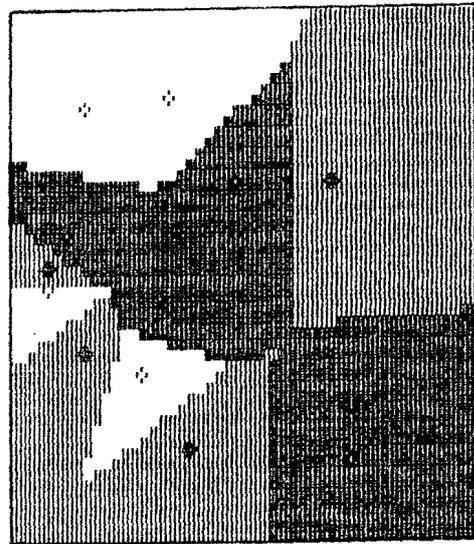


FIGURA 4.1.c.: Representação gráfica da distribuição espectral das classes geradas para a imagem sintética. Os valores do contador digital foram gerados a partir da estimativa dos parâmetros média e variância de uma imagem LANDSAT TM real da bacia do arroio Potiribú. A banda 2 corresponde à banda TM-4 e a banda 3 corresponde à banda TM-5.

Legenda: Classe 1 _____ .
 Classe 2 _____ +
 Classe 3 _____ □



sic
 classe 1 
 classe 2 
 classe 3 



sie
 classe 1 
 classe 2 
 classe 3 

FIGURA 4.2: Distribuição espacial das classes nas imagens sintéticas SIC e SIE geradas.

verdade de campo necessária para avaliar o desempenho do classificador.

A cobertura vegetal do solo nesta área está preponderantemente destinada à agricultura (soja e trigo). Existem também áreas menores cobertas por mata nativa, pasto e reforestamentos de eucaliptus e pinheiro. Devido à data de coleta dos dados ter coincidido com a época de colheita da soja, áreas cobertas por resteva desta cultura se encontram distribuídas na imagem. Da mesma forma, existem áreas com solo exposto em variados estágios de preparo. Esta imagem é denominada de "POTIRIBÚ" para fins deste estudo.

A figura 4.3 mostra um exemplo das fotografias oblíquas da região. Parte da imagem multiespectral utilizada é mostrada na figura 4.4. Nesta composição colorida, a banda TM-5 está associada à cor vermelha, a TM-4 à cor verde e a TM-3 à cor azul.

Duas áreas foram escolhidas a partir das fotografias aéreas, tomando em consideração o tipo da cobertura do solo. Elas estão mostradas nas figuras 4.5 e 4.6. Para fins deste estudo, elas serão denominadas de POTIRIBÚ-1 e POTIRIBÚ-2.

Na imagem Potiribú 1, mostrada na figura 4.5, aparecem diversas classes. A área central da imagem está ocupada por um campo de resteva (cor rosa), dividido ao meio por uma faixa ocupada por vegetação verde, provavelmente um mato. Uma área menor encontra-se também na parte central e está ocupada por vegetação densa. A prática agrícola desta região no período da coleta da imagem é colher a soja e deixar a resteva nos campos. Após um determinado tempo nas áreas já colhidas surge uma vegetação rasa, denominada "campo". Na parte inferior aparece uma área coberta por este tipo de cobertura. Na parte superior direita da imagem encontra-se uma área de mistura de classes. Esta área está associada a vegetação nativa que se encontra próxima a correiros, comumente denominada "mata de galeria". Uma área similar encontra-se no canto inferior direito da imagem. Parte destas áreas,

devido a sua proximidade aos correços, é comumente utilizada para campos de pastagem. A mancha escura, localizada no canto superior esquerdo da imagem, está ocupada por solo nú.

A figura 4.6 mostra a segunda área de teste, Potiribú 2. Nela encontra-se novamente uma área ocupada por vegetação densa, bosques de mata nativa, no centro da imagem. A área acima dela está coberta por "campo". Em torno delas encontram-se áreas de "resteva". Nota-se, no entanto, que a "resteva" tem variada resposta espectral, variando da cor rosa claro a escuro nesta composição. Observa-se, no canto superior direito, uma região de mistura. Esta mistura é típica em regiões próximas a correços, como comentado acima. Novamente, é difícil definir uma classe para esta região, mas por levantamentos de campo e análise das fotografias aéreas, pode-se dizer que mata nativa campo e pastagem são as classes comuns nesta região.

4.2. Testes

4.2.1. Testes com Imagens Sintéticas

A imagem sintética permite controle completo da exatidão do processo de classificação. Por este motivo os diferentes algoritmos foram primeiramente testados neste tipo de imagens. A seguir encontram-se descritos os experimentos realizados em imagens sintéticas (SIC e SIE) com o processo de relaxação probabilística, o processo de relaxação fuzzy, o processo combinado de filtragem no espaço das probabilidades, o processo fuzzy modificado com a média e o processo combinado de relaxação probabilística e fuzzy, descritos nos itens 4.2.1.2, 4.2.1.3, 4.2.1.5, 4.2.1.4 e 4.2.1.6. Mas já que todos eles se iniciam com a classificação pelo método da Máxima Verossimilhança Gaussiana, o resultado da primeira estimativa do valor das probabilidades é apresentada inicialmente.

4.2.1.1. Classificação Usando Unicamente Atributos Espectrais (pelo Método da Máxima Verossimilhança Gaussiana)

Imagem SIC:

Nesta imagem foram coletadas amostras para três classes denominadas (CL 3), (CL 2) e (CL 1), sendo a classe 0 considerada o "fundo" que no presente caso é vazia. A associação cor-canal utilizada foi a seguinte: canal azul-TM3, canal verde-TM4 e canal vermelho-TM5. As amostras são descritas no arquivo de classificação segundo mostrado na tabela 4.1.

TABELA 4.1: Parâmetros estatísticos das classes utilizadas na classificação da imagem SIC

classe	No. de pontos	vetor média	matriz de covariância		
1-CL 1	64	71.27	22.257568	-3.272949	6.003906
		49.97	-3.272949	11.561523	-1.492188
		28.75	6.003906	-1.492188	7.062500
2-CL 2	64	61.84	15.569336	0.677246	3.220703
		70.23	0.677246	66.741943	-6.854492
		25.31	3.220703	-6.854492	8.933594
3-CL 3	64	52.67	8.157959	6.62085	0.483398
		54.79	6.620850	16.068115	-0.209961
		25.19	0.483398	-0.209961	1.089844

Para a classificação pela Máxima Verossimilhança utilizou-se o limiar da estatística de Hotelling com nível de significância de $\alpha=90\%$ e probabilidades "a priori" iguais para todas as classes.

Os valores da estatística de Fisher resultantes são:

classe 1 = classe 2 = classe 3 = 2.179

Com o que o mínimo valor discriminante aceitável na fronteira que define a classe "fundo" (item 3.3.2) é de $6.656037e-28$, para a

estatística de Fisher $F_{3,64,\alpha=10\%}$

Imagem SIE:

Nesta imagem as amostras são descritas da seguinte forma no arquivo de classificação:

TABELA 4.2: Parâmetros estatísticos das classes utilizadas na classificação da imagem SIE

classe	No. de pontos	vetor média	matriz de covariância		
1-CL 1	64	71.75	21.3125	2.210938	3.5000
		50.16	2.210938	12.788086	-4.423828
		28.81	3.5000	-4.423828	6.371094
2-CL 2	64	61.84	15.544678	3.609619	0.698242
		71.33	0.609619	70.564209	-3.03418
		25.44	0.698242	-3.03418	10.589844
3-CL 3	64	52.67	8.157959	6.62085	0.483398
		54.79	6.62085	16.068115	-0.209961
		25.19	0.483398	-0.209961	1.089844

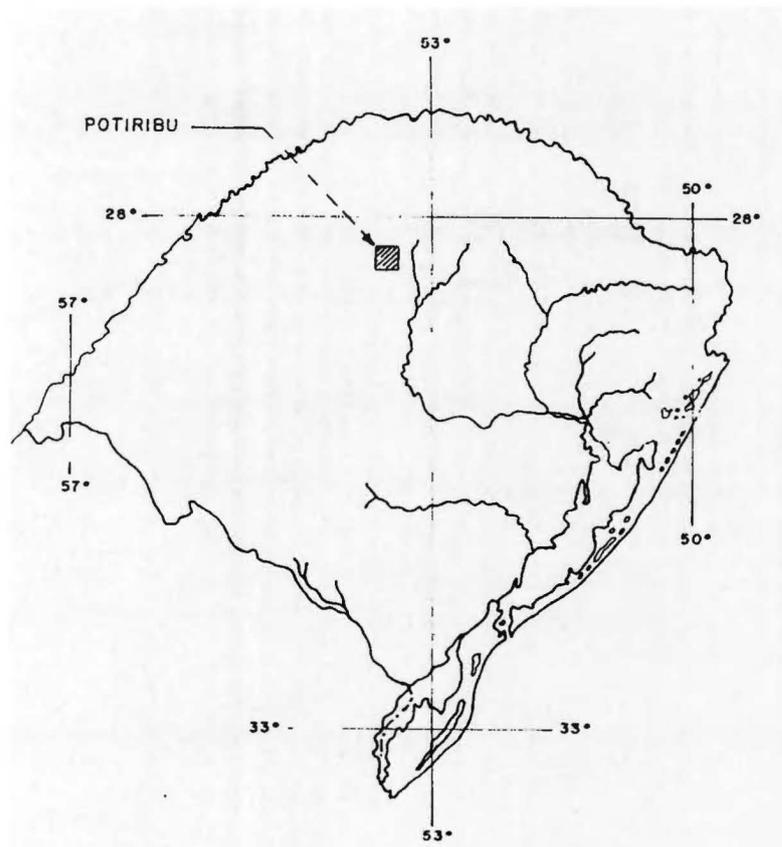
Para a classificação pela Máxima Verossimilhança utilizou-se o limiar da estatística de Hotelling com nível de significância de $\alpha=90\%$ e probabilidades "a priori" iguais para todas as classes.

Os valores da estatística de Fisher resultantes são:

classe 1 = classe 2 = classe 3 = 2.179

Com o que o mínimo valor discriminante aceitável na fronteira que define a classe "fundo" (item 3.8.2) é de $6.656037e-28$, para a estatística de Fisher $F_{3,64,\alpha=10\%}$

As estimativas dos parâmetros populacionais da distribuição das classes foram utilizadas para efetuar a classificação espectral das



Mapa de localização



FIGURA 4.3 Fotografia aérea da área de estudo localizada na bacia do rio Potiribú.



FIGURA 4.4: Fotografia de uma região da imagem utilizada como imagem de estudo



FIGURA 4.5: Fotografia de uma região da imagem utilizada como área teste Potiribú 1

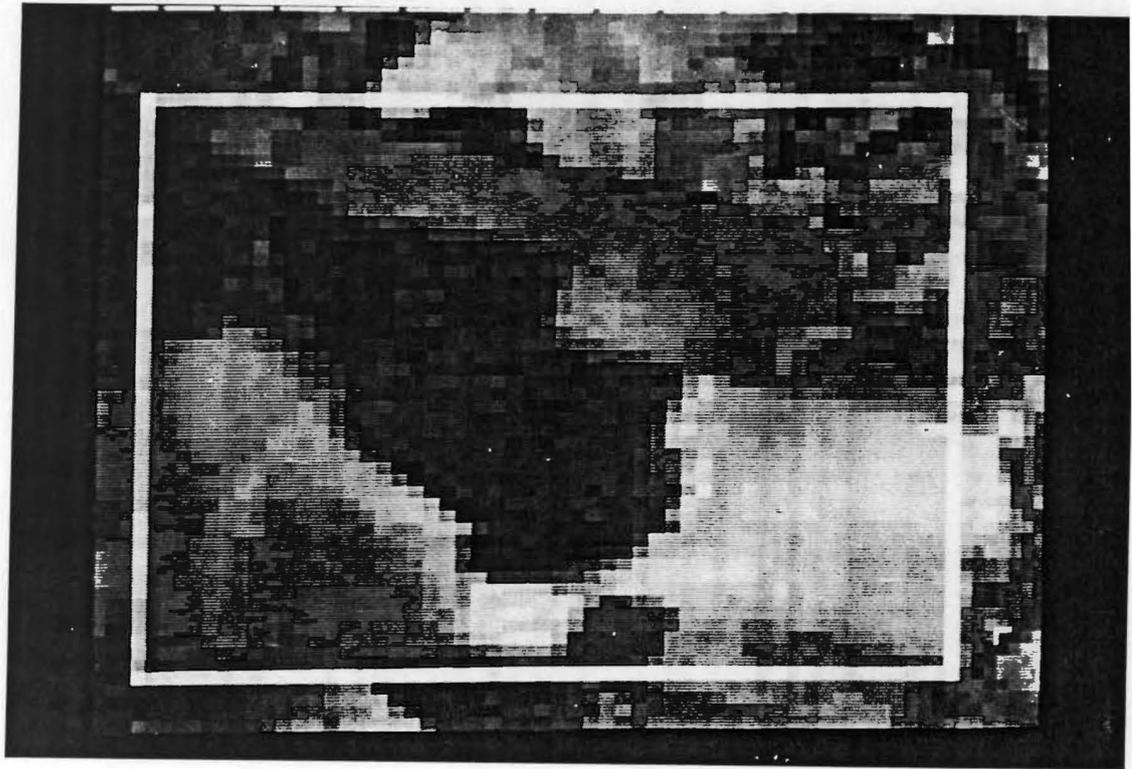


FIGURA 4.6: Fotografia de uma região da imagem utilizada como área teste Potiribú 2

imagens SIC e SIE.

4.2.1.2. Relaxação Probabilística

Partindo da imagem temática, obtida pela classificação que considera atributos puramente espectrais (Máxima Verossimilhança), foram estimados os coeficientes de compatibilidade para esta imagem, conforme descrito no item 3.3.4. Com base nestes dados foram implementados processos iterativos de classificação pelo processo da relaxação probabilística até atingir o ponto em que não se registrou variação entre a percentagem de pixels corretamente classificados de duas iterações sucessivas maior do que 0.01%.

Um processo semelhante ao anterior foi desenvolvido na imagem SIE. Os coeficientes de compatibilidade foram estimados a partir da classificação utilizando atributos espectrais. Uma série de 10 iterações da relaxação probabilística foi executada em função dos resultados obtidos na imagem SIC.

4.2.1.3. Relaxação Fuzzy

Partindo das estimativas obtidas pelo método da Máxima Verossimilhança Gaussiana, foi implementado o processo de iterativo de classificação pela relaxação fuzzy conforme descrito na seção 3.4.1.3. Os limiares fuzzy (τ e θ) foram estabelecidos em (0.4/0.5), (0.3/0.5), (0.2/0.5) e (0.15/0.5).

Um tratamento similar foi dado à imagem SIE. Na imagem SIE foram implementadas 4 iterações do processo de relaxação fuzzy. Como no caso da imagem SIC, os limiares fuzzy (τ e θ) foram estabelecidos em (0.4/0.5), (0.3/0.5), (0.2/0.5) e (0.15/0.5).

4.2.1.4. Relaxação Fuzzy com Introdução da Média

O processo de relaxação fuzzy modificado com o uso da média local

como limiar (conforme descrito na seção 3.3.6) foi também testado nas imagens sintéticas. As amostras utilizadas são as mesmas que nos dois casos anteriores.

Foram implementadas 7 iterações deste processo mantendo o segundo limiar fuzzy (τ) igual ao adotado nos testes da relaxação fuzzy, ou seja, igual a 0.5.

4.2.1.5. Processo Combinado de Filtragem e Relaxação Probabilística

Neste método, a imagem foi inicialmente classificada utilizando seus atributos espectrais. Os valores das funções discriminantes normalizadas para cada pixel foram discretizados em 8 bits e armazenados de forma semelhante à utilizada nas bandas espectrais. Essas novas "bandas" contendo os valores das funções discriminantes para cada classe foram então submetidas a uma filtragem no domínio espacial utilizando filtros do tipo passa-baixas. Entre os possíveis filtros do tipo passa-baixas (Schowengredt 1983) alguns foram escolhidos. Os filtros utilizados são mostrados na figura 4.7:

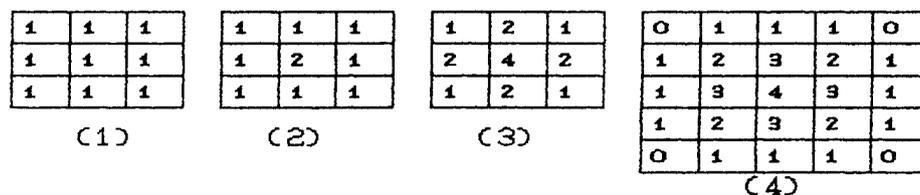


Figura 4.7: Filtros utilizados na filtragem espacial das bandas de funções discriminantes normalizadas

A Imagem SIC foi processada utilizando-se os quatro filtros mostrados na figura 4.7. Posteriormente, o processo de relaxação probabilística foi utilizado. No caso do filtro 1, foram realizadas duas iterações para avaliar melhor o número total necessário. Os demais filtros foram acompanhados por uma única iteração probabilística, em função do resultado obtido com o primeiro filtro (filtro 1). Os coeficientes de compatibilidade para esta imagem foram estimados a partir do mapa temático obtido previamente pelo método da

Máxima Verossimilhança.

Na imagem SIE foi testado o filtro tipo 3 em duas situações. Na primeira os coeficientes de compatibilidade foram estimados a partir da imagem classificada pelo método da Máxima Verossimilhança. Na segunda situação, os coeficientes foram estimados a partir da imagem classificada após o processo de filtragem espacial das probabilidades.

4.2.1.6. Processo combinado de Relaxação Probabilística e Relaxação Fuzzy.

O processo combinado proposto por Di Zenzo et alii. foi testado em ambas imagens sintéticas. Para isto, após a classificação utilizando os atributos espectrais pelo método da Máxima Verossimilhança, os coeficientes de compatibilidade foram estimados. Estes coeficientes foram utilizados nas primeiras quatro iterações segundo o método da relaxação probabilística. A seguir, quatro iterações da relaxação fuzzy foram empregadas. Os limiares fuzzy (τ e θ) foram estabelecidos em (0.4/0.5), (0.3/0.5), (0.2/0.5) e (0.15/0.5), respectivamente.

A intenção da primeira fase é diminuir a presença de pixels com baixo valor da probabilidade associada a uma classe dentro de regiões da imagem onde esta classe não é predominante. Como é explicado no item 4.3.1.3 dos resultados, a presença deste tipo de pixels prejudica a eficácia do processo de relaxação fuzzy. Por meio da relaxação probabilística pretende-se melhorar a estimativa das probabilidades $p_i(h)$ ao ponto em que a relaxação fuzzy possa implementada eficientemente. da mesma forma, pretende-se aproveitar o alto desempenho das primeiras iterações da relaxação probabilística e acelerar a classificação pela introdução do processo de relaxação fuzzy nas últimas iterações, onde a melhoria obtida com a relaxação probabilística é menor.

4.2.2. Testes com Imagens Reais

Uma análise detalhada dos testes desenvolvidos nessa pesquisa é apresentada no capítulo 5. Os resultados inicialmente obtidos a partir das imagens sintéticas serviram para orientar os testes utilizando imagens sintéticas. A análise dos resultados obtidos com as imagens sintéticas, comentados no item 4.3.1, serviram para tirar algumas conclusões úteis para definir os testes em imagens reais. Tendo se visto o baixo desempenho dos processos fuzzy nas imagens sintéticas (itens 5.1.3 e 5.1.4), eles não foram utilizados na segunda fase de testes. Os processos que produziram efetivamente uma melhoria na precisão da classificação das imagens sintéticas foram o processo de relaxação probabilística e o combinado de filtragem espacial e relaxação probabilística. Por isto, estes dois processos foram utilizados nas imagens reais.

Inicialmente foi efetuada a classificação espectral das imagens pelo método da Máxima Verossimilhança Gaussiana. As imagens temáticas desta primeira classificação foram utilizadas para a estimativa dos coeficientes de compatibilidade.

4.2.1.1. Classificação pelo Método da Máxima Verossimilhança Gaussiana

Imagem Potiribú-1

A análise visual das fotografias aéreas indicaram a presença de quatro classes dentro da área, as quais foram identificadas da seguinte forma:

- Vegetação densa (bosques)
- Campos cobertos por resteva
- Campo
- Pastagem

Para estimar os parâmetros que caracterizam estas classes foram

escolhidas áreas dentro da imagem, mas não necessariamente dentro da área teste. As áreas puderam ser escolhidas a partir das fotografias aéreas, nas quais se identificaram locais onde as classes aparecem claramente, sem confusão com outras classes. A classe "solo exposto" não foi incluída nesta classificação. As classes são descritas da seguinte forma no arquivo de classificação:

Nomes: classe 1 : Vegetação densa
 classe 2 : Resteva
 classe 3 : Campo
 classe 4 : Pastagem

Número de pontos : n
 Vetor de médias : \underline{m}
 Matriz de covariância : Σ
 Estatística de Fisher : F

classe	n	\underline{m}	Σ			F
1	64	31.79	8.9743	6.5972	1.2070	2.179
		45.09	6.5972	15.6787	1.4296	
		13.25	1.2070	1.4296	0.7500	
2	64	30.89	29.9099	7.3730	4.6811	2.179
		37.12	7.3730	4.9531	0.6679	
		42.65	4.6811	0.6679	5.4130	
3	49	82.26	8.8483	1.3085	1.1846	2.215
		51.87	1.3085	3.4426	-0.1245	
		32.61	1.1846	-0.1245	1.7068	
4	49	72.10	21.4789	5.0483	2.1427	2.215
		69.33	5.0483	69.0362	-12.5510	
		26.00	2.1427	-12.551	6.1632	

Para o cálculo da estatística de Fisher, para cada classe, a significância da estatística de Hotelling foi fixada em $\alpha=90\%$. As probabilidades "a priori" foram consideradas iguais. Com isto, o valor mínimo aceitável das funções discriminantes, e por conseguinte o valor que define a classe "fundo" (item 3.3.2), é de 1.709128×10^{-10} .

Imagem Potiribú-2

Foram identificadas cinco classes na área denominada Potiribú-2.

Elas são:

- Vegetação densa (Bosques de eucaliptus)
- Resteva (em dois estágios diferentes: Resteva 1 e Resteva 2)
- Área cultivada (sob duas formas: Campo 1 e campo 2).

Novamente, áreas conhecidamente ocupadas por cada uma das classes foram utilizadas para estimar os parâmetros de cada uma delas. Eles são descritos a seguir:

Nomes: classe 1 : Vegetação densa
 classe 2 : Resteva 2
 classe 3 : Resteva 1
 classe 4 : Campo 1
 classe 5 : Campo 2

classe	n	\bar{m}	Σ			F
1	108	35.93	52.3386	39.4523	7.2431	2.139
		49.12	39.4523	63.7351	5.4652	
		13.75	7.2431	5.4652	2.3541	
2	60	92.21	126.6706	32.0371	9.8742	2.186
		37.59	32.0371	10.0735	2.1735	
		41.43	9.8747	2.1735	3.3277	
3	60	106.31	106.1161	0.1955	-4.2000	2.286
		44.38	0.1955	2.7032	2.8667	
		50.00	-4.2000	2.8667	4.5667	
4	40	78.17	14.8940	13.3277	-0.7446	2.245
		69.12	13.3277	17.6094	-1.3296	
		28.45	-0.7446	-1.3296	1.4630	
5	50	92.40	19.2396	1.0640	2.5682	2.126
		44.34	1.0640	4.9844	-2.6591	
		34.87	2.5682	-2.6591	3.4658	

Para o cálculo da estatística de Fisher, para cada classe, a significância da estatística de Hotelling foi fixada em $\alpha=90\%$. As

probabilidades "a priori" foram consideradas iguais. Com isto, o valor mínimo aceitável das funções discriminantes, e por conseguinte o valor que define a função discriminante da classe "fundo" (item 3.3.2), é de 1.150706×10^{-31} .

4.2.2.2. Relaxação Probabilística

Os resultados obtidos com as imagens SIC e SIE foram utilizados para determinar o número de iterações a ser utilizado em imagens reais. Em situações reais, a precisão da classificação não pode ser conhecida. Assim, o limiar escolhido para interromper o processo de relaxação probabilística nas imagens sintéticas não é adequado ao caso de imagens reais.

Como Eklundh [1980] faz notar, a taxa média de variação pode ser utilizada para determinar o ponto a partir do qual novas iterações no processo de relaxação probabilística não trazem contribuição significativa à precisão da classificação. Na imagem SIC, o incremento na taxa de pixels corretamente classificados é menor a 0.1% após a décima iteração. Nessa iteração, a taxa média de variação chegou a 0.002916. Na imagem SIE, isto acontece após a nona iteração, quando a taxa média de variação é de 0.003995. Tomando em consideração estas duas situações, ficou estabelecido que quando a taxa média de variação for inferior a 0.003000, o processo de relaxação seria terminado.

4.2.2.3. Processo Combinado de Filtragem Espacial e Relaxação Probabilística

Como aconteceu nas imagens sintéticas, no processo combinado de filtragem espacial no domínio das probabilidades foi utilizado o filtro tipo 3. Os valores das funções discriminantes, calculadas pelo método da Máxima Verossimilhança, foram discretizadas em 8 bits (256 níveis) e armazenadas em bandas similares às utilizadas em imagens multiespectrais, que podem ser filtradas utilizando os algoritmos do sistema SITIM. Após a filtragem, a imagem foi submetida a uma iteração

da relaxação probabilística. Como o processo de filtragem espacial é muito rígido, alguns erros são gerados por ele, particularmente em regiões onde o valor das probabilidades na vizinhança de um pixel nem sempre assumem valores próximos para uma mesma classe. Isto geralmente acontece em pixels próximos às bordas, onde pixels de diferentes classes podem estar presentes na vizinhança. Por isso, a relaxação probabilística é utilizada para contornar tais situações através do uso dos coeficientes de compatibilidade espacial.

V RESULTADOS

No apêndice "A", são apresentados os resultados de cada um dos experimentos realizados utilizando os diferentes algoritmos propostos no capítulo 3. São apresentadas as imagens classificadas em diferentes estágios de cada processo. Paralelamente, são apresentadas as matrizes de confusão (para as imagens sintéticas), a entropia e a taxa média de variação para alguns estágios. A taxa de pixels corretamente classificados é calculada dividindo o somatório da diagonal da matriz de confusão pelo número total de pixels na área teste e pode ser calculada unicamente para as imagens sintéticas.

Primeiramente são apresentados os resultados com as imagens sintéticas SIC e SIE. Na matriz de confusão as classes estão identificadas da seguinte maneira:

classe 1: CL 1
classe 2: CL 2
classe 3: CL 3
classe 0: Fundo (CL 0 = classe de rejeição)

5.1. Imagens Sintéticas

5.1.1. Classificação Usando Unicamente Atributos Espectrais

As imagens temáticas resultantes da classificação, pelo método da Máxima Verossimilhança Gaussiana, para as imagens SIC e SIE são apresentadas nas figuras A1 e A2.

Analisando a matriz de confusão (tabelas A1 e A2) observa-se que 94,88% dos pixels que compõem a imagem SIC foram corretamente classificados. Na imagem SIE esta fração chega a 94,92%.

A maior confusão é encontrada entre as classes (3) e (2), em ambas imagens. Na imagem SIC, a confusão chega a 4.04% e na imagem SIE é de 3.6%. Por outro lado, a menor confusão está associada às classes

(1) e (3). Esta esta confusão é de 0.96%, na imagem SIC, e de 1.36%, na imagem SIE. Estes fatos também podem ser observados nas representações gráficas das imagens temáticas mostadas nas figuras A1 e A2.

De forma geral, pode-se dizer que a classificação pelo método da Máxima Verossimilhança Gaussiana (MVG) foi correta. Os erros são causados pelo natureza aleatória assumida na geração dos números digitais em cada banda. Estes erros serão submetidos a processos de classificação contextual.

A amostragem é um fator determinante na qualidade da imagem temática. Quando ela não é suficientemente representativa, a confusão entre classes aumenta, e com isto diminui a fração de pixels corretamente classificados. Nas situações aqui analisadas, a diferença entre as frações de pixels corretamente classificados das imagens SIC e SIE é muito pequena (94.92% e 94.88%), e pode-se considerar que ambas classificações são muito similares quanto a exatidão. Com isto, as divergências que possam surgir nos ganhos obtidos com os processos contextuais não dependem da qualidade da primeira estimativa de $p_i(h)$ e sim da distribuição espacial e da estimativa dos coeficientes de compatibilidade.

Em ambas as imagens não houve rejeição, em função de não existirem outras classes nas cenas. Outra causa para a ausência da classe "fundo" é o baixo valor calculado para o mínimo valor aceitável na fronteira do elipsoide de confiabilidade (6.65×10^{-28} , na imagem SIE, e na imagem SIC.)

As fronteiras espaciais entre classes mostram-se bem definidas nas imagens classificadas. Isto não acontece frequentemente em situações reais, porque nelas existem fatores, como a presença de pixels com mais de uma classe presente na sua área (pixels mistura) ou pixels que sofrem o efeito da sombra, que podem prejudicar a classificação.

5.1.2. Relaxação Probabilística

Imagem SIC

Diferentes estágios do processo de relaxação probabilística aplicada à imagem SIC são mostrados nas figuras A4a após 2 iterações, A4b, após 5 iterações, e A4c, após 10 iterações, do anexo A. Uma análise visual destas representações gráficas evidencia a melhora obtida com o processo contextual. A evolução da matriz de confusão pode ser vista nas tabelas A3 a A12 do anexo A.

Após 2 iterações, a imagem classificada evidencia a ausência de pixels mal classificados na área ocupada pela classe (1). Os erros mostrados na matriz de confusão devem-se a pixels nas bordas do espaço ocupado pela classe. A classe (2) também teve a sua precisão aumentada, sendo que a confusão entre as classes (3) e (2) foi minimizada. A situação da classe (3) também foi melhorada neste estágio do processo de relaxação probabilística. Em função da maior confusão desta classe com a classe (2) e, em menor intensidade, com a classe (1), muitos erros ainda existem na área ocupada por esta classe. Os pixels da classe (1) classificados como sendo da classe (3) pelo processo da Máxima Verossimilhança Gaussiana, foram eliminados após a primeira iteração. Após duas iterações, a confusão entre a classe (2) e (3) diminuiu significativamente (de 101 a 66 pixels). A precisão da classificação foi aumentada em 2.2% após as primeiras duas iterações.

O processo de relaxação probabilística foi terminado quando se registrou um incremento na precisão inferior a 0.1% entre duas iterações sucessivas. Na imagem SIC um valor inferior a 0.1% foi alcançado após 6 iterações mas posteriormente os valores aumentaram e ficaram acima de 0.1% até a nona iteração. Após a décima iteração, os valores registrados ficaram abaixo de 0.1%. O maior valor para a precisão foi registrado após a nona iteração, e é de 99.20%, o que corresponde, no caso de estudo, a 20 pixels mal classificados. Após a décima iteração, se registra uma queda no número de pixels corretamente classificados. Embora muito pequena (equivale a 1

pixel), isto indica que o processo iterativo alcançou um ponto onde a contribuição à precisão da imagem temática é muito pequena. Deve-se tomar em consideração que o processo contextual após um determinado número de iterações pode facilitar o surgimento de novas classificações erradas, especialmente nas fronteiras entre imagens, onde a vizinhança dos pixels não é homogênea. Por este motivo, não foram consideradas mais iterações após a décima.

A classificação após 10 iterações mostra uma melhora significativa (de 94.88 a 99.76%). A maior confusão ainda é encontrada entre as classes (3) e (2), sendo que os erros nas classes (1) e (2) foram quase totalmente corrigidos. Isto pode ser atribuído à distribuição espectral das classes mostrado no item 4.2.1.1 e na figura 4.1. Os vetores de médias da classe (3) e (2) estão mais próximos um do outro do que da classe (1). A distribuição espectral das classes torna-se importante na estimativa dos coeficientes de compatibilidade. Como é mostrado na figura A4 e na tabela A1, a maior confusão está associada às classes (3) e (2). Por este motivo a compatibilidade entre pixels destas classes é maior e, conseqüentemente, os erros envolvendo estas duas classes são corrigidos com menor severidade. Por outro lado, a compatibilidade entre pixels da classe (1) é reforçada. O resultado desta estimativa da compatibilidade é a maior suavização encontrado na área ocupada pela classe (1).

No final do processo iterativo existem 21 pixels mal classificados, sendo que 10 deles nunca poderiam ser melhorados pelo processo contextual por se encontrarem nas bordas da imagem e a vizinhança não estar definida para eles.

Imagem SIE

A partir da imagem classificada pela Máxima Verossimilhança Gaussiana (figura A2), os coeficientes de compatibilidade foram estimados. Eles foram utilizados para o processo de relaxação probabilística.

As figuras A3a, A3b e A3c do anexo "A" mostram as imagens temáticas após 2, 6 e 10 iterações, respectivamente. A evolução da matriz de confusão neste processo é apresentada nas tabelas A13 a A22.

Tendo visto que o ponto fixado para interromper o processo iterativo foi alcançado após 10 iterações na imagem SIC, o mesmo número de iterações foi inicialmente fixado para a imagem SIE. A precisão máxima alcançada foi de 98.48% e o incremento total na precisão após 10 iterações é de 3.56%.

Após 6 iterações, a imagem temática apresenta uma melhoria significativa com número de erros reduzido. A confusão entre as classes (3) e (2) é alta, sendo que a classe mais desfavorecida é a classe (3), onde o número de pixels mal classificados é de 28. Existe uma parcela de pixels mal classificados nas fronteiras entre classes que não puderam ser corrigidos. Novamente, a área ocupada pela classe (1) foi a que mostrou maior melhora. Analisando a distribuição espectral das classes, item 4.2.1.2. e figura 4.1, a classe (3) é a que mais se confunde com as outras duas e a que mais facilmente se separa é a classe (1). Isto justifica os resultados obtidos na classificação espectral. Analisando a imagem temática após a classificação espectral, observa-se que a classe (3) é a que está mais freqüentemente associada a erros na classificação, seja dentro da área ocupada pela classe (3), onde se apresentam pixels classificados como pertencentes à classe (2), ou na área correspondente à classe (2), onde a presença de pixels da classe (3) é significativa. Já a classe (1) está relacionada a um menor grau de confusão, o que também é mostrado na matriz de confusão da tabela A1. O grau de confusão espacial influencia diretamente a estimativa do coeficiente de compatibilidade. Como foi descrito no item 3.3.4, o coeficiente de compatibilidade é estimado a partir de co-ocorrência de classes em posições adjacentes na imagem temática obtida pelo processo da Máxima Verossimilhança. Por este motivo, os coeficientes da classe (1) favorecem a homogeneização das áreas ocupadas por esta classe. Pelo mesmo motivo, por ser a confusão da classe (3) maior, a homogeneização de suas áreas na imagem temática é menor.

Após 10 iterações, a imagem temática mostra um maior grau de homogeneidade dentro das classes. O número de pixels mal classificados cai de 127 (pelo método da Máxima Verossimilhança) a 38 (após 10 iterações) sendo que 16 deles se encontram nos cantos da imagem onde o contexto não foi definido.

Comparando as imagens temáticas das duas imagens após o processo de relaxação probabilística, nota-se que o melhor desempenho se registrou na imagem SIC, onde as classes encontram-se mais agrupadas. Na mesma imagem, se alcançou 99.76% de pixels correlamente classificados, sendo que na imagem SIE este valor atinge 98.48%, fato que pode ser claramente visto nas imagens temáticas correspondentes. De modo geral, a cada iteração a precisão é aumentada em ambas imagens, sendo que as maiores contribuições acontecem nas primeiras iterações e caem após cada iteração. (tabelas A68 e A69).

A diferença no ganho obtido na precisão da classificação das duas imagens pode ser atribuída à distribuição espacial das classes. Como na imagem SIE as fronteiras entre classes são mais frequentes, a compatibilidade entre classes diferentes é maior que a encontrada na imagem SIC. Assim, a suavização de áreas ocupadas por uma classe é maior na imagem SIC. Isto não significa que o processo de relaxação contextual seja eficiente unicamente em áreas homogêneas mas, devido às características espaciais das imagens sintéticas aqui utilizadas, a compatibilidade entre pixels de mesma classe é reforçada, favorecendo a classificação contextual dentro de áreas homogêneas.

A entropia e a taxa média de variação para estas duas imagens estão presentes nas tabelas A68 e A69. De modo geral, a taxa média de variação diminui após cada iteração em ambos os experimentos e tende a zero. Da mesma forma, a entropia decresce em ambas as situações de maneira muito parecida. As maiores variações acontecem nas primeiras iterações e tendem a se anular na medida em que o número de iterações aumenta.

5.1.3. Relaxação Fuzzy

As figuras A6 e A7 do anexo "A" mostram as imagens temáticas após as quatro iterações do processo de relaxação fuzzy para as imagens SIC e SIE. A evolução da matriz de confusão neste processo está mostrada nas tabelas A23 e A30.

O ponto fixado para encerrar o processo não foi alcançado, pois não se registrou aumento na precisão. Pelo contrário, a precisão diminui a cada iteração deste processo. Na imagem SIC a precisão final é de 80.20% e na imagem SIE de 80.28%. A queda registrada é de 14.64 (366 pixels) na imagem SIE e de 14.68% (367 pixels) na imagem SIC.

Em ambos casos, após 4 iterações, a imagem temática se mostra significativamente degradada. A confusão entre as classes é aumentada. Nota-se que os pixels mal classificados pelo método da Máxima Verosimilhança Gaussiana originam erros adicionais nos pixels que os circundam. Isto pode ser explicado da seguinte forma: O processo de relaxação fuzzy é caracterizado por ser capaz unicamente de diminuir o valor da função de pertinência do pixel central. Além disso, o novo valor não é normalizado, como acontece na relaxação probabilística. Por este motivo a presença de valores muito baixos na vizinhança de um pixel (próximos de zero), podem anular o valor de sua função de pertinência. O seguinte exemplo pode ilustrar esta situação, em uma janela 3x3, considerando duas classes e limiares (0.4 e 0.5):

	classe 1		classe 2
	0.9	1.0	0.9
	0.7	0.85	1.0
	0.0	1.0	0.8

FIGURA 5.1 - Exemplo de valores das probabilidades normalizadas dentro de uma vizinhança definida em duas classes.

Na figura 5.1, está representada a janela 3x3 implementada em duas classes. Como é visto, existem em ambos casos além do pixel

central, oito vizinhos que formam o contexto do pixel. Para cada posição na janela encontra-se o valor respectivo da probabilidade a ela associada ao pixel.

O valor para a classe 1 é calculado assim para uma sub-vizinhança consecutiva de três pixels, segundo o definido no item 3.3.5.:

l	$\bigvee_{\theta} p(l+q)$	$p(i) \wedge_{\tau} \bigvee_{\theta} p(l+q)$
1	1.0	1.0
2	1.0	1.0
3	1.0	1.0
4	1.0	1.0
5	0.0	0.0
6	0.0	0.0
7	0.0	0.0
8	1.0	1.0

O valor de "l" define a posição da janela. Para cada valor de "l" os dois vizinhos seguintes, segundo a ordem estabelecida na figura 3.2, são considerados. Entre estes três valores, o maior, em relação ao limiar 0.4, é determinado. Pelo exposto no item 3.3.5, se pelo menos um deles for menor ao limiar, o menor valor é adotado. Já se todos eles forem menores ou maiores ao limiar, o maior valor é escolhido. Os valores assim calculados para cada "l" são mostrados na segunda coluna. Note-se que a presença de valores muito baixos dentro da sub-vizinhança determinam um valor baixo para esta operação. Na terceira coluna são mostrados os valores resultantes da operação fuzzy $p(i) \wedge_{\tau} \bigvee_{\theta} p(l+q)$. Isto equivale a dizer que o maior valor entre os dois argumentos do operador é escolhido se ambos estão acima ou abaixo do limiar (0.5) simultaneamente. Se pelo menos um deles estiver abaixo do limiar, ele será escolhido. Por este motivo, a presença de valores de probabilidade baixos influencia o valor da probabilidade resultante para a classe. Para o exemplo utilizado, o menor destes valores é 0.0. Este valor é calculado a partir das janelas mostradas na figura 5.1.

Para o mesmo exemplo da figura 5.1, o valor para a classe 2 é calculado assim para sub-vizinhanças de três pixels (ou seja, q=2 na

formulação do item 3.3.5):

1	$\bigvee_{\theta} p(1+q)$	$p(1) \wedge_{\tau} \bigvee_{\theta} p(1+q)$
1	0.1	0.15
2	0.1	0.15
3	0.2	0.2
4	0.3	0.3
5	0.3	0.3
6	0.3	0.3
7	0.3	0.3
8	0.3	0.3

O menor destes valores é 0.15.

Comparando ambos valores, a classificação resultante atribui o pixel central à classe 2. Analisando a mesma situação visualmente, pode-se notar que tal classificação não está correta já que a vizinhança do ponto mostra elevados valores da função de pertinência associada à classe 1 e baixos à classe 2. A presença do pixels com valor de função de pertinência $p(1)=0.0$ na vizinhança afeta significativamente o resultado da relaxação fuzzy neste ponto. Como consequência, os valores dos pixels vizinhos a pixels com baixo valor de função de pertinência mudam de classe e são classificados como erros.

A entropia e a taxa média de variação para estas duas imagens estão presentes nas tabelas A70 e A71. Após cada iteração a taxa média de variação diminui, mas seu valor é muito superior comparado com os obtidos com a relaxação probabilística. A causa desta diferença é a normalização realizada no processo probabilístico que suaviza a alteração da probabilidade do pixel central.

A entropia aumenta em ambas imagens a cada iteração do processo fuzzy. A evolução da entropia nas duas situações sugere a convergência a um valor limite superior. No entanto, esta afirmação não pode ser considerada verdadeira sem realizar experiências mais prolongadas. O aumento da entropia é um efeito não desejado. As maiores variações na entropia acontecem nas primeiras iterações e diminuem a cada iteração.

5.1.4. Processo de Relaxação Fuzzy Modificado com a Média

Imagem SIC

7 iterações deste processo modificado foram executadas na imagem SIC. As imagens temáticas aparecem na figura A8 do anexo "A". A tabela A31 mostra a evolução da matriz de confusão neste processo.

A primeira iteração aumenta a precisão da classificação, mas as seguintes têm o efeito contrário. A taxa de pixels corretamente classificados máxima alcançada é de 98.20% e a final de 97.12%. Nota-se que este processo é mais eficiente que o processo fuzzy original, mas não é capaz de melhorar a classificação.

Imagem SIE

O mesmo número de iterações foi executado na imagem SIE, e as respectivas imagens temáticas aparecem na figura A7 do anexo "A".

Uma análise da matriz de confusão (figuras A38 e A44) constata os fatos observados na experiência com a imagem SIC. A maior taxa de pixels corretamente classificados corresponde à primeira iteração (96.20%) e a taxa final é muito inferior à original (95.28%)

Mesmo com a vantagem deste processo em relação à relaxação fuzzy anterior, ele não é eficiente e a precisão diminui. As tabelas A72 e A73 mostram os valores da entropia e a taxa média de variação para SIC e SIE. Os valores da taxa média de variação são maiores em relação aos obtidos com os outros processos. Eles mostram uma tendência a cair após cada iteração (de 0.285694 na primeira iteração a 0.287851 na sétima iteração, na imagem SIC e de 0.247828 a 0.249358 na imagem SIE).

A entropia aumenta rapidamente em ambas imagens quando comparada com a evolução da entropia nos outros processos. Não pode-se notar evidência de convergência após as sete iterações. O valor após a última iteração é de 0.225545 para a imagem SIE, e de 0.257851 para a

imagem SIC.

5.1.5. Teste da Implementação do Processo de Filtragem no Domínio das Probabilidades

5.1.5.1. Teste de Diferentes Filtros

Os filtros descritos na seção 4.2.1.5 foram testados e mostraram ser eficientes quanto ao aumento da precisão. A imagem utilizada no teste foi a imagem SIC. Como o teste dos filtros foi realizado em uma primeira fase, as áreas teste que foram utilizadas na estimativa dos parâmetros das classes são diferentes. Por tal motivo, as estimativas dos parâmetros das classes não foram as mesmas que as usadas nos outros processos contextuais.

A tabela A76 do anexo "A" mostra o resumo dos resultados deste teste. A figura A9 mostra a imagem temática após o processo combinado utilizando o filtro tipo 3.

A taxa de pixels corretamente classificados com a Máxima Verossimilhança Gaussiana é de 95.32%. A implementação do filtro tipo 1 aumenta esta taxa a 95.60%. Uma segunda iteração usando o mesmo filtro o diminui para 95.36%.

Utilizando o filtro tipo 2 a taxa de pixels corretamente classificados é de 96.08%, superior à anterior. A diferença neste caso é o maior peso atribuído ao pixel central. O terceiro filtro segue uma abordagem similar, dando peso maior aos pixels mais próximos do pixel central. Esta situação demonstra ser mais eficiente e aumenta a taxa de pixels corretamente classificados a 97.72%. O quarto filtro é uma janela 5x5 similar à anterior. A precisão neste caso sobe a 97.08%.

A análise visual das imagens classificadas usando filtragem espacial, revela um bom grau de homogeneização nas áreas ocupadas por uma única classe, mas da mesma forma nota-se que as fronteiras espaciais entre classes são prejudicadas, ou seja, nas fronteiras

entre classes são introduzidos erros pela filtragem espacial. Isto se justifica em função da alta heterogeneidade das classes presentes na vizinhança de pixels localizados na fronteira. Espectralmente estes pixels não seriam difíceis de classificar porque sua resposta espectral não é afetada pela proximidade da fronteira como acontece em cenas reais. No entanto, o processo de filtragem espacial diminui significativamente o valor de uma classe em pixel localizados na fronteira pois, conjuntamente a valores altos, encontram-se valores baixos para as probabilidades normalizadas. Através da filtragem, os valores das probabilidades nas fronteiras são diminuídos a um valor médio, o que prejudica sua classificação, visto que estes novos valores filtrados serão utilizados para definir a nova classificação do pixel. Pode então acontecer que o valor filtrado associado à verdadeira classe de pixel seja menor que o valor da probabilidade associada a outra classe. Este fato, no entanto, não acontece em regiões homogêneas.

A classe (3) é a que apresenta menor homogeneização interna. Observa-se também que na fronteira entre duas classes surge uma faixa de pixels classificados como pertencendo à terceira. Isto se nota especialmente entre as classes (1) e (2), onde surge a classe (3) na fronteira (figura A9).

5.1.5.2. Aplicação do Processo Combinado de Filtragem Espacial e Relaxação Probabilística

Tendo em vista a eficiência demonstrada pelo filtro tipo (3) (seção 4.2.1.5), unicamente este foi utilizado na primeira parte do processo combinado de filtragem espacial e relaxação probabilística, nas imagens SIC e SIE. Para corrigir os erros gerados na filtragem, foi utilizada a relaxação probabilística.

As tabelas A45 a A51 do anexo "A" resumem os resultados obtidos com este processo combinado e a evolução das matrizes de confusão são mostradas nas tabelas A75 e A76. Nestes testes, a classificação espectral é a mesma utilizada nos outros processos de relaxação.

Inicialmente, unicamente uma iteração probabilística foi empregada na imagem SIC. O ganho na precisão na imagem SIC, avaliado através da matriz de confusão, é de 4.36%. A análise das imagens temáticas (figura A11) mostra a melhora obtida neste processo. Nelas pode-se ver a faixa de pixels mal classificados que surge na fronteira entre as classes (1) e (2) e que posteriormente é eliminada pela relaxação probabilística. Como acontece nos outros processos, os erros localizados nas fronteiras da imagem permanecem e não podem ser eliminados.

Na imagem SIE, foram utilizadas duas iterações da relaxação probabilística. O ganho na precisão é de 4.12%, após a primeira iteração e diminui para 4.08% após a segunda. As imagens temáticas mostram novamente o surgimento dos pixels mal classificados na fronteira entre as classes (1) e (2) após a filtragem espacial e sua correção por meio da relaxação probabilística. A segunda iteração não apresentou melhoria nos resultados pelo que uma única iteração da relaxação probabilística pode ser considerada suficiente neste caso. Esta afirmação no entanto deve ser cuidadosamente considerada pois ela foi obtida a partir de unicamente dois testes com imagens sintéticas, pelo que não poderia ser generalizada a imagens reais sem as respectivas considerações. A figura A10 mostra as imagens temáticas correspondentes.

A relaxação probabilística utilizada nos casos anteriores estima os coeficientes de compatibilidade a partir da imagem temática resultante do processo da Máxima Verossimilhança. Um segundo teste foi efetuado na imagem SIE com a estimativa dos coeficientes de compatibilidade a partir da imagem temática obtida após a filtragem espacial, por considerar que desta forma se favoreceria a co-ocorrência de pixels de mesma classe em posições adjacentes. O resultado pode ser visto na figura A11. A taxa de pixels corretamente classificados alcança 99.04%, o que equivale a um ganho de 4.12%, após a primeira iteração, e não aumenta após a segunda. A imagem temática resultante (figura A11) mostra como a classificação é melhorada.

Os resultados do processo combinado são alentadores. A taxa de pixels corretamente classificados não chega a 100% devido à presença de pixels nas bordas da imagem. O efeito dado às imagens temáticas é claramente superior quando comparado com os outros processos contextuais.

5.1.6. Processo Combinado de 4 Relaxações Probabilísticas e 4 Relaxações fuzzy

As imagens temáticas A12 e A13 do anexo "A" mostram as imagens deste processo. Os valores respectivos para a evolução da matriz de confusão estão mostrados nas tabelas A53 a A67.

Como acontece no processo de relaxação fuzzy, o ponto fixado para encerrar o processo não foi alcançado. No entanto, analisando o número de pixels corretamente classificados, nota-se que unicamente o processo probabilístico resulta em uma melhoria da imagem temática. Após a quarta iteração, a fração de pixels corretamente classificados diminui, como acontece com a relaxação fuzzy.

Novamente, as imagens temáticas mostram que os pixels próximos àqueles classificados erroneamente são afetados e desta forma os erros se propagam na imagem temática. Após as oito iterações a precisão na imagem SIC cai para 93.08% e na imagem SIE para 92.68. O ganho obtido com as iterações da relaxação probabilística é perdido com a relaxação fuzzy. Pior ainda, novos erros são introduzidos.

A entropia cai durante as iterações probabilísticas e aumenta durante a relaxação fuzzy. Da mesma forma, a taxa média de variação se comporta diferente em cada uma das fases do processo (tabelas A72 e A73). Como se esperava, a taxa de variação da função de pertinência, que relaciona os pixels às classes, assume valores relativamente grandes, quando comparados com aqueles obtidos na relaxação probabilística. Considerando esta diferença na ordem de grandeza, nota-se que durante as iterações fuzzy, de maneira geral, o valor da taxa de variação tende a diminuir.

5.2. Imagens Reais

5.2.1. Classificação Usando Unicamente Atributos Espectrais

Imagem Potiribú 1.

O processo de classificação pelo método da Máxima Verossimilhança Gaussiana produziu a imagem temática mostrada na figura A14a. No caso da imagem Potiribú-1, encontram-se áreas homogêneas de tamanho relativamente grande na parte central da mesma, e uma região de mistura espacial das classes na parte esquerda. A mistura é caracterizada pela presença de vegetação densa associada a áreas próximas a córregos ou zonas mais baixas. Neste caso, a resposta espectral da vegetação é influenciada pela presença de sombra, umidade e outros elementos como solo ou tipos diferentes de vegetação, com diferentes respostas espectrais. Torna-se difícil separar esta classe sem prejudicar a classificação de outras áreas da cena, em função da mencionada variedade de elementos. No entanto, a classificação pelo método da Máxima Verossimilhança Gaussiana consegue identificar a predominância da classe "pastagem" nessas áreas, o que é correto.

A área central da imagem está ocupada por um campo coberto por resteva. Este foi bem identificado pela classificação espectral. Na sua parte central, nota-se a presença de uma faixa ocupada por vegetação baixa e densa. A análise visual da imagem mostra que esta faixa está localizada numa região mais baixa e não é ocupada, portanto, pela classe "resteva", e sim por vegetação. Existe ainda, na imagem temática (figura A14a), uma pequena ilha de 2 pixels classificados como campo e pastagem. Esta ilha, na realidade, faz parte da faixa de vegetação localizada na região mais baixa comentada anteriormente. A classificação pela Máxima Verossimilhança Gaussiana mascarou parte da faixa isolando estes dois pixels, porém, eles estão corretamente classificados.

Houve rejeição na classificação. Existe uma faixa estreita que separa o "campo" da "resteva", ocupada pela classe "fundo". O

surgimento desta faixa pode ser explicado pelo efeito conhecido como "pixel mistura" (Haertel e Silva Centeno 1991). A rigor é difícil encontrar pixels que não sejam "pixels mistura" em uma cena natural, pois na área ocupada por cada pixel na superfície da Terra geralmente existe mais de um elemento (vegetação e solo, por exemplo) misturados, o que altera a resposta espectral do pixel. Assim, pelo critério de exclusão adotado, tais pixels não pertencem a nenhuma das classes ditas "puras" consideradas na classificação.

Uma área de confusão aparece também rodeando a classe "vegetação densa", onde os pixels são classificados como "pastagem".

Imagem Potiribú 2.

A imagem temática resultante do processo de classificação da imagem Potiribú 2, pelo método da Máxima Verossimilhança Gaussiana, é apresentada na figura A15a. Nessa imagem, existem também áreas homogêneas e áreas de mistura espacial de classes, gerando portanto pixels "puros" e pixels "mistura". A parte superior direita da figura A15a mostra uma área de confusão onde várias classes se misturam formando uma região heterogênea. A análise visual, do canto superior direito da imagem temática, confirma que os pixels classificados como "vegetação densa" nesta região são na realidade pixels ocupados por "pastagem", escurecidos pelo efeito da sombra. Desta forma, espectralmente parecem ser "vegetação densa", o que se revela na classificação pelo método da Máxima Verossimilhança Gaussiana. Devido à mistura nesta região, manchas da classe "fundo" são mais frequentes, o que pode ser considerado correto.

Do centro da imagem para baixo, as classes ocupam áreas homogêneas maiores. O bosque localizado no centro da imagem é corretamente identificado pelo classificador espectral. Da mesma maneira, os campos cobertos por "resteva" (tipo 1 e 2) estão corretamente classificados.

O surgimento de diferentes classes (por exemplo "pastagem" e fundo) nas fronteiras espaciais, novamente se torna evidente nesta

imagem temática, como pode ser observado no contorno do bosque central. A área de fronteira entre o bosque (vegetação densa) e a área ocupada pela classe "campo 2", está parcialmente ocupada por pixels não classificados (classe fundo e "campo"), como acontece na imagem Potiribú 1.

Através da análise visual das duas imagens reais pode-se afirmar que ambas estão corretamente classificadas espectralmente. Pode-se notar ainda que o limiar estabelecido para o critério de rejeição, devido à sua natureza especial, favorece à inclusão dos pixels em uma das classes, diminuindo a taxa de pixels rejeitados. Comparando as imagens temáticas obtidas por este método com aquelas obtidas pelo processo clássico da Máxima Verossimilhança Gaussiana, nota-se que a taxa de pixels rejeitados é inferior, e portanto, a imagem temática é semelhante àquela obtida pela classificação clássica a um nível de significância maior (por exemplo $\alpha=97.5\%$). Como foi comentado no capítulo 3 (item 3.3.2.), não existe uma função discriminante para a classe "fundo", pelo que uma simplificação neste sentido é necessária. A simplificação adotada aqui é a proposta por Di Zenzo et alii. [1989] e serve para conservar o nível de significância estabelecido para todas as classes.

5.2.2. Relaxação Probabilística

Imagem Potiribú 1

A evolução da taxa média de variação foi monitorada após cada iteração do processo de relaxação probabilística. Um total de 22 iterações foram necessárias para alcançar o ponto fixado como final do processo. Diferentes estágios da imagem temática ao longo deste processo são mostrados na figura A14. Os valores da taxa média de variação e da entropia após cada iteração são mostrados na tabela A77.

Nota-se um maior grau de homogeneização da imagem temática na medida que o processo da relaxação probabilística avança. As taxas de variação mais altas acontecem nas primeiras iterações, e a taxa de variação diminui ao longo do processo. Na imagem temática final, os

pixels localizados na área de confusão, na parte superior direita da imagem, estão mais adequadamente agrupados segundo a classe. Assim, um maior número de pixel é atribuído à classe "pastagem".

Um processo similar é evidente no canto inferior direito da imagem. Aqui, os pixels inicialmente classificados como "pastagem" na área ocupada por "campo" são removidos. O mesmo acontece no canto inferior esquerdo, onde alguns pixels originalmente classificados como "resteva" são classificados como "campo", após o processo contextual.

A faixa ocupada por "campo" e "pastagem" localizada dentro do campo de "resteva" no centro da imagem é preservada. O mesmo não acontece com os pixels isolados formando uma ilha no centro deste campo, os quais, após o processo de relaxação probabilística, estão diminuídos em quantidade e alterados quanto à sua classificação, passando a fazer parte da classe de rejeição.

A taxa média de variação neste teste mostra uma tendência a diminuir após cada iteração. Após a primeira iteração o seu valor é de 0.012992 e passa a ser de 0.002889 após a 22ª. iteração. As maiores alterações no valor da taxa média de variação acontecem nas primeiras iterações.

A evolução da entropia ao longo do processo iterativo evidencia uma tendência a diminuir após cada iteração. O valor inicial, após a classificação pelo método da Máxima Verossimilhança Gaussiana, é de 0.098159 e cai a 0.041802 no final do processo de relaxação probabilística.

Imagem Potiribú 2.

A evolução da imagem temática durante a classificação contextual da imagem Potiribú 2, segundo a relaxação probabilística, é mostrada na figura A15. A parte superior direita da imagem temática, que mostra uma área de confusão após a classificação espectral, permanece, de uma forma geral, muito heterogênea, mas nota-se algum grau de homogeneização, embora a imagem temática não tenha melhorado

significativamente nesta região.

Um maior grau de suavização pode ser visto na parte inferior da imagem, principalmente na área ocupada por resteva tipo 1 e 2. Os campos de maior tamanho, situados do centro da imagem para baixo, não são afetados pelo processo. Suas fronteiras são preservadas, não ocorrendo a degradação das mesmas como resultado do processo contextual.

A faixa de rejeição (classe "campo"), na fronteira espacial entre as classes, não é corrigida. Ela permanece igual ao longo do processo. Este fato pode ser considerado correto, se se leva em consideração que os pixels situados nesta região apresentam resposta espectral distinta daquelas correspondentes às classe "puras".

5.2.3. Processo Combinado de Filtragem e Relaxação Probabilística

Imagem Potiribú 1

Nota-se um alto grau de homogeneização da imagem temática após o processo combinado de filtragem espacial das bandas de probabilidades normalizadas seguida de uma iteração da relaxação probabilística, sendo que a maior suavização da imagem temática acontece após a filtragem espacial.

O efeito produzido com a filtragem mascara a presença de pixels isolados dentro de áreas homogêneas. A filtragem prejudica em parte a imagem temática, pois junto aos pixels considerados "ruído" produzidos na classificação pela Máxima Verossimilhança Gaussiana, os pixels isolados classificados corretamente na base dos atributos espectrais são removidos da imagem temática.

O processo contextual da relaxação probabilística, aplicado à imagem após a filtragem, recupera parte dos pixels isolados que foram removidos da imagem pela filtragem. A imagem temática resultante é mostrada na figura A16. Comparando esta figura com a imagem temática obtida pela classificação espectral (figura A14a), verifica-se que a

região de mistura espacial entre classes, localizada no canto superior direito da figura, é melhorada, destacando a presença da classe "pastagem", o que ocorre também no canto inferior direito da imagem. A área ocupada por "campo" também foi suavizada e nela os pixels rejeitados aparecem mais agrupados, formando grupos compactos.

Um fato de particular significado acontece no campo de "resteva" no centro da imagem. Aqui, os pixels isolados localizados no centro do campo, comentados no item 5.1.2, foram classificados como "resteva" em função da sua vizinhança. Tal classificação não é correta, porque a análise visual da imagem original revela que estes pixels não são da classe "resteva". Como resultado, a faixa ocupada por "campo" e "pastagem" localizada dentro do campo de "resteva" no centro da imagem é mascarada.

Imagem Potiribú 2.

O estado intermediário da imagem temática Potiribú-2, após a filtragem espacial das bandas das funções discriminantes normalizadas é apresentado na figura A17a. Na figura A17b encontra-se a representação gráfica da imagem temática após a classificação contextual da mesma após uma iteração do processo de relaxação probabilística.

Após a filtragem, a parte superior direita das imagens temáticas, que mostra uma área de confusão após a classificação espectral, é suavizada, mas ainda apresenta características de heterogeneidade. Nota-se a remoção dos poucos pixels classificados como "fundo" (classe de rejeição) no contorno do bosque, localizado no centro da imagem. Como acontece na imagem Potiribú-1, a filtragem também prejudica os pixels isolados corretamente classificados por meio da Máxima Verossimilhança.

Após a iteração da relaxação probabilística, algumas classificações erradas, introduzidas pelo processo de filtragem, são recuperadas. A faixa de pixels da classe "campo" na fronteira superior do bosque aparece novamente na imagem temática.

De uma forma geral, as imagens são suavizadas após o processo combinado. Elas mostram superfícies maiores de áreas homogêneas, quando comparadas com às imagens temáticas resultantes da classificação pelo método da Máxima Verossimilhança Gaussiana e os limites espaciais entre classes não são significativamente alterados, quando se tratam de áreas relativamente grandes. A correção contextual acontece mais freqüentemente associada a grupos pequenos de pixels ou a pixels isolados. Esse fato é coerente com o princípio básico da filtragem espacial, que pondera o valor atribuído ao pixel em função de sua vizinhança imediata. Em se tratando de classes ocupando áreas mais extensas na imagem, a função discriminante normalizada tende a ser similar para todos os pixels na região, razão pela qual a alteração do seu valor não é significativa. O contrário acontece nas áreas onde as classes aparecem formando grupos menores. Nestos casos, a função discriminante normalizada pode ser alterada pela influência de valores de probabilidade apresentando alta variabilidade na vizinhança. Isto é visto nas imagens temáticas (figuras A16a e A17b) onde os grupos maiores de pixels de mesma classe não são alterados.

VI CONCLUSÕES

O uso dos atributos de contexto na classificação digital de imagens de satélite foi estudado, como meio de aprimorar a tarefa de mapeamento da cobertura vegetal de bacias hidrográficas e estimar parâmetros hidrológicos. Os processos de relaxação foram escolhidos para esta finalidade. Inicialmente, foi feita uma revisão desses processos e da estimativa dos coeficientes de compatibilidade, que representam a probabilidade de co-ocorrência de classes em posições espacialmente adjacentes.

Para iniciar o processo de relaxação, é necessária uma estimativa inicial da probabilidade de cada pixel pertencer a cada uma das classes consideradas. Estas probabilidades devem ser exaustivas e normalizadas. Como em cenas reais geralmente existe um maior número de classes do que aquelas consideradas na classificação, uma classe de rejeição foi criada. Esta classes, denominada "fundo", representa todas as classes não consideradas na classificação. O processo da Máxima Verossimilhança Gaussiana foi escolhida como meio de obter a primeira estimativa, em função dela ser um método estatisticamente fundamentado e considerar o vetor de médias e a matriz de covariância de cada classe. Devido à natureza particular da classe "fundo", não existe uma estimativa da função discriminante para esta classe, pelo que algumas simplificações no critério de rejeição foram realizadas.

O cálculo dos coeficientes de compatibilidade é de fundamental importância no processo de relaxação. A estimativa aqui apresentada, é baseada no conceito de informação mútua entre dois eventos. Desta maneira, os coeficientes de compatibilidadae puderam ser estimados a partir da imagem classificada pelo método da Máxima Verossimilhança Gaussiana.

Simultaneamente, um novo algoritmo foi desenvolvido como variação do processo de relaxação probabilística. Ele se compõe da combinação da filtragem espacial das funções discriminante normalizadas e a relaxação probabilística. Isto foi feito com a intenção de acelerar o

processo iterativo.

Os algoritmos propostos foram implementados em programas compatíveis com o sistema de tratamento de imagens SITIM-150 do CEP SRM. Eles foram testados inicialmente em imagens sintéticas geradas para esta finalidade, e posteriormente em situações reais. No segundo caso, uma bacia real foi escolhida, de forma a tornar o teste mais próximo de uma situação real de pesquisa hidrológica.

No caso da imagens sintéticas, a precisão da classificação foi monitorada através da matriz de confusão entre classes após cada iteração. Simultaneamente, a taxa de variação e a entropia foram monitoradas. Nas imagens reais, a classificação correta da imagem não era conhecida, pelo que a precisão fornecida pelos processos propostos, nestas situações, não pode ser monitorada. No entanto, a taxa de variação e a entropia puderam ser calculadas.

Os testes com imagens sintéticas revelaram que o uso de atributos contextuais aumenta a precisão de classificação, pelo método da Máxima Verossimilhança Gaussiana, e podem produzir mapas temáticos mais apropriados para a interpretação e uso em estudos da cobertura vegetal como elemento ativo nos processos hidrológicos que acontecem na bacia hidrográfica.

Dos processos testados, o processo de relaxação probabilística e o combinado de filtragem espacial das funções discriminantes normalizadas e relaxação probabilística foram os que melhores resultados apresentaram. Já o processo de relaxação fuzzy não demonstrou ser útil nesta tarefa, embora tenha sido introduzida uma série de simplificações e adaptações na tentativa de torná-lo mais eficiente.

No caso de imagens sintéticas, o maior incremento na precisão está relacionado ao processo combinado de filtragem espacial e relaxação probabilística. Aplicado às imagens sintéticas a precisão aumenta em 4.36% e 4.12% (figuras A18 e A19).

O processo de relaxação probabilística aumenta a precisão da classificação após cada iteração. O incremento diminui ao longo do processo, tendendo a zero. Nas figuras A18 e A19, esta tendência pode ser observada. O incremento total alcançado com este tipo de relaxação varia entre 4.32% e 3.56%.

A evolução da precisão, no caso da relaxação fuzzy, não é alentadora. Ela cai após cada iteração, chegando a uma perda total da precisão em torno de 14.68% e 14.65% após quatro iterações. Para diminuir esta desvantagem, a média local foi introduzida como um dos limiares fuzzy. Com isto se conseguiu diminuir suas deficiências, mas não foi possível aumentar significativamente a precisão da classificação. O aumento maior se registrou na primeira iteração, após a qual a tendência foi diminuir. (figuras A18 e A19).

Da mesma forma, um processo misto da relaxação probabilística e a relaxação fuzzy foi testado. As primeiras iterações regidas pela relaxação probabilística deveriam aumentar a precisão a um ponto em que as situações que poderiam gerar erros no processo fuzzy fossem minimizadas. Isto não aconteceu. Notou-se a queda da precisão a cada iteração da relaxação fuzzy, embora a perda registrada após cada iteração tenha sido relativamente menor do que a correspondente ao processo fuzzy simples (figuras A18 e A19).

Analisando as figuras (A20 e A21), correspondentes à taxa de variação, conclui-se que ela cai lentamente no processo de relaxação probabilística, tendendo a zero no final do processo. Este comportamento era esperado e reflete o fenômeno observado na evolução da precisão no mesmo processo. Na medida em que a taxa de variação diminui, as alterações nos valores das funções discriminantes normalizadas são menores e, por conseguinte, o mapa temático sofre menor número de alterações. O comportamento da taxa média de variação em relação à precisão indica que ela pode ser utilizada para fixar o ponto onde o processo de relaxação deve ser detido, ou seja, onde o ganho obtido não é mais relevante.

De maneira similar, nos processo de relaxação fuzzy e fuzzy modificado com a média, a taxa de variação diminui lentamente. Os valores correspondentes a estes processos são, no entanto, superiores aos registrados na relaxação probabilística. Isto se justifica em função da falta de normalização das funções de pertinência após cada iteração. Em nenhum processo fuzzy se chegou a valores notadamente próximos de zero. No processo combinado de relaxação probabilística e fuzzy, uma mudança brusca do valor da taxa de variação corresponde ao ponto onde o processo de relaxação probabilístico é trocado pelo processo fuzzy.

Unicamente o valor da entropia no processo de relaxação probabilística mostra uma tendência decrescente (figuras A22 e A23). O decréscimo da entropia reflete a tendência da imagem se tornar mais homogênea. Na medida que ela decresce, portanto, as alterações das probabilidades, associando o pixel a cada classe em função do contexto imediato do pixel, tornam-se menores.

Nas relaxações fuzzy, a entropia cresce após cada iteração, não se notando tendência a diminuir. Chama a atenção o comportamento da entropia no processo de relaxação fuzzy modificada com a média local, que é notadamente crescente, a uma taxa quase constante, embora a análise das imagens temáticas e da precisão da classificação mostre que este processo não é tão ineficiente quanto o fuzzy simples.

Inicialmente os processos de filtragem espacial foram estudados separadamente. O teste de vários filtros revelou que este tipo de processamento consegue efetivamente melhorar a classificação da imagem. Entre eles se destaca o filtro passa-baixas denominado "tipo 3" neste estudo (figura 4.7), com o qual se consegue um aumento de 2.43%. No entanto, notou-se que, ao mesmo tempo que os erros dentro de áreas homogêneas eram corrigidos, novos erros na classificação foram gerados nas fronteiras espaciais entre classes com este processamento. O processo combinado de filtragem e relaxação probabilística se comporta melhor quando os coeficientes de compatibilidade utilizados

são aqueles estimados a partir da imagem classificada pelo método da Máxima Verossimilhança Gaussiana. Da mesma forma, se verificou que uma iteração da relaxação probabilística após a filtragem é suficiente para corrigir os erros gerados pela filtragem. Quando aplicado às imagens sintéticas, este processo combinado demonstrou ser o mais eficiente, aumentando a precisão em torno de 4.36% e 4.12% (figuras A18 E A19).

Os resultados obtidos em imagens sintéticas são geralmente superiores aos obtidos em imagens reais. Por este motivo, unicamente os processo de melhores resultados foram utilizados em situações reais. Os resultados obtidos com imagens reais comprovaram a eficiência dos processos de relaxação probabilística e combinado de filtragem espacial e relaxação probabilística.

A relaxação probabilística é um processo lento, mas efetivo. Nela existe a vantagem da preservação de certa parcela da informação espectral. Os processos de uniformização comumente utilizados consideram unicamente a informação da imagem temática, pelo que os pixels isolados dentro de áreas homogêneas são removidos sem maiores considerações. A relaxação probabilística preserva tais pixels quando o valor da probabilidade ligado à classe "invasora" é elevado em relação ao associado à classe da vizinhança. Isto é correto e vantajoso, pois preserva maior quantidade de informação e unicamente altera os pixels em situações onde o valor das probabilidades associados a diferentes classes, para o mesmo pixel, são similares, o que refletiria a ambigüidade da situação. A maneira de contornar esta ambigüidade, em função da compatibilidade espacial das classes, é apropriada para imagens do tipo utilizado em sensoriamento remoto, pois ela se adapta a cada situação e não segue uma lei independente da distribuição espacial das classes na imagem.

O processo combinado de filtragem e relaxação probabilística suaviza as áreas homogêneas mas, comparado com a relaxação probabilística, perde o detalhe dos pixels corretamente classificados como pertencendo a uma classe diferente da sua vizinhança. Isto era

esperado, pois o processo de filtragem considera preponderantemente a relação espacial entre pixels, em prejuízo dos atributos espectrais de cada pixel. A correlação entre pixels de mesma classe em posições adjacentes é válida na maior parte da imagem, onde os pixels formam grupos maiores, mas falha, como seria de esperar, em regiões de fronteira espacial entre classes ou quando existem pixels isolados dentro de áreas ocupadas por outras classes. A lei que rege a filtragem não se adapta a cada situação, porque suaviza tanto áreas homogêneas como de misturas espacial. A preservação da classificação correta de pixels dentro de áreas homogêneas, de classes diferente, pode ser alcançada dando um peso maior ao ponderador espacial do pixel central da janela utilizada na filtragem.

De forma geral, as imagens temáticas obtidas pelos dois processos em situações reais são também mais apropriadas para a análise visual e provavelmente são mais apropriadas para uso em outros sistemas digitais, como por exemplo os do tipo SIG (Sistema de Informação Geográfica), pois nelas as classes se encontram mais agrupadas espacialmente, formando aglomerados que são mais fáceis de interpretar ou poligonizar. Em hidrologia, isto se traduz em uma maior facilidade de caracterização da cobertura vegetal em bacias hidrográficas, simplificando a tarefa de estimativa de parâmetros hidrológicos.

Os métodos aqui utilizados armazenam o valor das probabilidades na forma de contadores digitais variando de 0 a 255. Com isto se perde informação em troca de menor quantidade de memória de computador utilizada. É de se esperar que os processos sejam mais bem sucedidos utilizando o valor completo da função discriminante, pois assim a discretização entre duas probabilidades é maior. O formato aqui empregado demonstrou, entretanto, ser eficiente.

Metodologias capazes de acelerar a convergência dos processos de relaxação devem ser procuradas. Isto pode tornar a relaxação probabilística mais apropriada para seu uso em tratamento de imagens digitais. Da mesma forma, novas alternativas de se estimar o coeficiente de compatibilidade podem acrescentar vantagens a estes

processos.

A informação que pode ser obtida a partir da exploração dos atributos contextuais depende da maneira e precisão com que a relação contextual entre classes pode ser estimada. No presente estudo, esta relação foi implementada na forma de coeficientes de compatibilidade. Esta não é a única solução existente, mas demonstrou ser eficiente para a finalidade. O ganho obtido com a informação contextual significa maior precisão na classificação e, portanto, a estimativa de parâmetros relacionados à cobertura do solo torna-se mais fácil e eficiente.

O presente estudo demonstra que os atributos de contexto servem para aumentar a informação obtida a partir de imagens de satélite a respeito da cobertura vegetal de bacias hidrográficas. No entanto, deve-se considerar o alto custo de processamento de algoritmos como a relaxação probabilística na hora de optar por uma determinada metodologia de classificação. O balanço entre a precisão e o custo (tempo de processamento) definem a estratégia mais apropriada a cada finalidade. Existem situações que exigem um conhecimento mais detalhado da cobertura vegetal em bacias, onde os processos contextuais podem ser empregados. Como exemplo pode-se citar a localização de áreas favoráveis a erosão ou o monitoramento de mudanças na superfície da bacia. Por outro lado, em outras situações estimativas menos precisas podem ser suficientes.

VII BIBLIOGRAFIA

- BORDAS M. P., Lanna A. E. e Luca S. J. de, (1990) *Projeto Potiribu. Avaliação e Controle dos Impactos da Agricultura sobre os Recursos Hídricos do Derrame Basáltico Sulamericano*. 42o Reunião Anual de SBPC. Porto Alegre RS. Comunicação 09-A1-vol I pp.15/16.
- CHEVRES, Michele et alii., (1981). *The SPOT Satellite Remote Sensing Mission.*, Photogrametric Engineering and Remote Sensing, Vol. 47, No. 8, agosto de 1981, pp. 1163-1171.
- DI ZENZO, Silvano, Bernstein R. De Gloria S. D. e Kolsky H. G., (1989). *Gaussian Maximum Likelihood and Contextual Classification Algorithms for Multicrop Classification*. IEEE Transactions on Geoscience and Remote Sensing, Vol. GE 25, No. 6, novembro de 1987, pp.805-814
- DI ZENZO Silvano, De Gloria S. D., Bernstein R. e Kolsky H. G., (1989). *Gaussian Maximum Likelihood and Contextual Classification Algorithms for Multicrop Classification Experiments Using Thematic Mapper and Multispectral Scanner Sensor Data*. IEEE Transactions on Geoscience and Remote Sensing, Vol. GE 25, No. 6, novembro de 1987, pp.815-824
- DUDA, Richard O. e Hart, Peter E., (1973). *Pattern Classification and Scene Analysis*. Nova York-USA, John Wiley and Sons, cap. 1,2.
- EKLUNDH, J. O., Yamamoto H. e Rosenfeld A., (1980). *A Relaxation Method for Multiespectral Pixel Classification*. IEEE Transactions on Pattern analysis and Machine Inteligence, Vol PAMI-2, No. 1, janeiro de 1980. Pp 72-75.
- HAERTEL V. e Silva Centeno J. A., (1991). *Utilização do Conceito de Pixel Mistura no processo de Classificação da Cobertura do Solo em Bacias Hidrográficas*. Submetido à Revista Brasileira de Engenharia, Caderno de Recursos Hídricos (a ser publicada 1991).
- HARALICK, Robert, (1983), *Decission Making in Context*. IEEE Transactions on Pattern analysis and Machine Inteligence,

- Vol. PAMI-5, No. 4, julho de 1983. pp.417-428.
- HSIAO, J. Y. e Sawchuk, A. A., (1989). *Supervised Textured Image Segmentation Using Feature Smoothing and Probabilistic Relaxation*. IEEE Transactions on Pattern Analysis and machine Intelligence, Vol. 11, No. 12, dezembro de 1989.
- JOHNSON, Richard A. e Wichern Dean W. (1982). *Applied Multivariate Statistical Analysis*, USA, Prentice Hall Inc., parte 1,2.
- JUSTICE, Chris e Townshend, John, (1982). *A Comparison of Unsupervised Classification Procedures on LANDSAT MSS Data for an Area of Complex Surface Conditions in Basilicata, Southern Italy*. Remote Sensing of Environment, 1984, No. 12, pp. 407-420.
- KANDEL, Abraham, (1986). *Fuzzy Mathematical Techniques with Applications*, USA, Addison-Wesley Publications Co., cap. 1.
- KANDEL, Abraham e Lee Samuel C., (1979). *Fuzzy Switching and Automata : Theory and Applications*. Nova York-USA, Crane Rusak & Co., cap. 1,2.
- KAUFMANN, H. et alii., (1986). *Design of Spectral and Panchromatic Bands for the German MOMS-02 Sensor*. Photogrammetric Engineering and Remote Sensing and Remote Sensing, Vol. 47, No. 6, junho de 1986, pp.875-881.
- KITTLER, Josef e Pairman D., (1985). *Contextual Pattern Recognition Applied to Cloud Detection and Identification*. IEEE Transactions on Geoscience and Remote Sensing, Vol. GE-23, No. 6, novembro de 1989.
- LANDGREBE, David A., (1978). *Remote Sensing; the Quantitative Approach*. West Lafayette-USA, McGraw-Hill, inc., pp. 1-16.
- LANDGREBE, David. A., (1980). *The Development of a Spectral-Spatial Classifier for Earth Observational Data*. Pattern Recognition 1980, Vol. 12, pp. 165-175.
- LeROY, F. S., (1978). *Remote Sensing; the Quantitative Approach*. West Lafayette-USA, McGraw-Hill, inc., pp. 21-133.
- MOLLER-JENSEN, Lasse, (1990). *Knowledge-based Classification of an Urban Area Using Texture and Contextual Information in LANDSAT TM Imagery*. Photogrammetric Engineering and Remote

- Sensing, Vol. 56, No. 6, Junho de 1990, pp.899-904.
- MOHN, Erik, Hjort N. L. e Storkiv G. O., (1987). *A Simulation Study of Some Contextual Classification Methods for Remotely Sensed Data*. IEEE Transactions on Geoscience and Remote Sensing, Vol GE25, No.6, novembro de 1987, pp. 796-804
- NAGY, George, (1984). *Advances in Information Extracting Techniques*. Remote Sensing of Environment , 1984, No.15, pp. 167-175.
- NOVO, Evlyn, (1988). *Sensoriamento Remoto :Princípios e Aplicações*, São José dos Campos - Brasil , INPE/MCT, cap. 1,2.
- PAL, Sankar K. et alii., (1986). *Fuzzy Mathematical Approach to Pattern Recognition*, Nova York - USA, John Willey & Sons, cap. 1,2.
- PAIVA FILHO, Augusto et alii., (1988) *Utilização de Imagens LANDSAT TM no Inventário Hidroenergético da Bacia do Rio Paraíba do Sul*. IV Simpósio Brasileiro de Sensoriamento Remoto, pp.645-653.
- PELEG S. e Rosenfled A., (1978)., *Determining Compatibility Coefficients for Curve Enhancement Relaxation Processes*. IEEE Transactions on Systems, Man and Cybernetics, Vol.SAMC-8, No. 7, Julho de 1978. pp.548-555.
- PISSANI, Alfredo, (1989). *Sensoriamento Remoto por Satélite Aplicado à Bacia Hidrográfica*. VII Simpósio Brasileiro de Recursos Hídricos Vol 2. Ppp.347
- RAGAN, Robert e Jackson, Thomas. (1975).*Use of Satellite Data in Urban Hidrologic Models*. Journal of the Hidrauluc Division, dezembro de de 1975, pp. 1469.
- RAGAN, Robert e Jackson, Thomas. (1980).*Runoff synthesis using Landsat and SCS model*. Journal of the Hidrauluc Division, Maio de 1980 pp. 667.
- RICHARDS, J.A., Landgrebe D. A. e Swain P. H., (1980). *Pixel Labeling by Probabilistic Relaxation* . IEEE Transactions on Pattern analysis and Machine Inteligence, Vol PAMI-2, No.1, janeiro de 1980. pp.188-1815.

- ROSENFELD, A., Hummel R. e Zucker S. W., (1976). *Scene Labeling by Relaxation Operations*. IEEE Transactions on Systems, Man and Cybernetics, Vol. smc-6, No. 6, Junho de 1976. pp.420-433.
- SCHOWENGERDT, Robert A., (1983). *Techniques for Image Processing and Classification*. Londres-Inglaterra, Academic Press Inc.
- SLATER, Philip N., (1980). *Remote Sensing, Optics and Optical Systems*. Massachusetts-USA, Addison-Wesley Publishing Co. inc., pp. 1-46.
- STAFFORD, Donald et alii. (1973). *Utilization of Aerial Photographs for Measuring Land Use Changes in Watersheds*. Remote Sensing and Water Resources Management, American Water Resources Association, junho de 1973, Proc. No. 17, Urbana Illinois, pp. 313.
- STRAHLER; Alan H., (1980). *The Use of Prior Probabilities in Maximum Likelihood Classification of Remote Sensed Data*. Remote Sensing of Environment Vol. 10, 1980, pp. 135-163.
- SWAIN, P. H. et alii., (1978). *Remote Sensing; the Quantitative Approach*. West Lafayette-USA, McGraw-Hill, inc., pp. 137-185.
- SWAIN, Philip H., Vardeman S. B. e Tilton J. C., (1981). *Contextual Classification of Multispectral Image Data*. Pattern Recognition, Vol. 13, No. 6, 1981, pp.429-441.
- TAO, Tao e Kouwen, Nicholas., (1989). *Remote Sensing and Fully Distributed Modelling for Flood Forecasting*. Journal of Water Resources Planning and management, Vol. 115, no. 6, Nov. 1989 pp. 811-823.
- TILTON, James C. Vardeman S. B. e Swain P. H., (1982). *Estimation of Context for Statistical Classification of Multispectral Image Data*. IEEE Transaction on Geoscience and Remote Sensing, Vol. GE 20, No.4, outubro de 1982, pp. 445-452.
- VIEIRA, Carlos et alii., (1989). *Potencialidade do Uso de Dados de Satélite no Mapeamento de Planícies de Inundação*. VII Simpósio Brasileiro de Recursos Hídricos, Vol.2, pp.347.
- WANG Fuangju, (1990). *Fuzzy Supervised Classification of Remote Sensing Images*. IEEE Transactions on Geoscience and Remote Sensing. Vol. 28 No.2, pp. 194-201.

- ROSENFELD, A., Hummel R. e Zucker S. W., (1976). *Scene Labeling by Relaxation Operations*. IEEE Transactions on Systems, Man and Cybernetics, Vol.smc-6, No. 6, Junho de 1976. pp.420-433.
- SCHOWENGERDT, Robert A., (1983). *Techniques for Image Pcessing and Classification*. Londres-Inglaterra, Academic Press Inc.
- SLATER, Philip N., (1980). *Remote Sensing, Optics and Optical Systems*. Massachusetts-USA, Addison-Wesley Publishing Co. inc., pp. 1-46.
- STAFFORD, Donald et alii. (1973). *Utilization of Aerial Photographs for Measuring Land Use Changens in Watersheds*. Remote Sensing and Water Resources Management, American Water Resources Association, junho de 1973, Proc. No. 17, Urbana Illinois, pp. 313.
- STRAHLER; Alan H., (1980). *The Use of Prior Probabilities in Maximum Likelihood Classification of Remote Sensed Data*. Remote Sensing of Environment Vol. 10, 1980, pp. 135-163.
- SWAIN, P. H. et alii., (1978). *Remote Sensing; the Quantitative Approach*. West Lafayette-USA, McGraw-Hill, inc., pp. 137-185.
- SWAIN, Philip H., Vaderman S. B. e Tilton J. C., (1981). *Contextual Classification of Multispectral Image Data*. Pattern Recognition , Vol. 13, No. 6, 1981, pp.429-441.
- TAO, Tao e Kouwen, Nicholas., (1989). *Remote Sensing and Fully Distributed Modelling for Flood Forecasting*. Journal of Water Resources Planning and management, Vol. 115, no. 6, Nov. 1989 pp. 811-823.
- TILTON, James C. Vaderman S. B. e Swain P. H., (1982). *Estimation of Context for Statistical Classification of Multispectral Image Data*. IEEE Transaction on Geoscience and Remote Sensing, Vol. GE 20, No.4, outubro de 1982, pp. 445-452.
- VIEIRA, Carlos et alii.,(1989). *Potencialidade do Uso de Dados de Satélite no Mapeamento de Planícies de Inundação*. VII Simpósio Brasileiro de Recursos Hídricos, Vol.2, pp.347.
- WANG Fuangju, (1990). *Fuzzy Supervised Classification of Remote Sensing Images*. IEEE Transactions on Geoscience and Remote Sensing. Vol. 28 No.2, pp. 194-201.

WHARTON, Stephen W., (1982). *A Contextual Classification Method for Recognizing Land Use Pattern in High Resolution Remotely Sensed Data*. Pattern Recognition 1982, Vol. 5, No.4 , pp.317-324.

ZUCKER, Steven W. Krishnamurthy E. V. e Haar R. L., (1978). *Relaxation Processes for Scene Labelling : Convergence, Speed and Stability*. IEEE Transaction on Sytems, man and cybernetics, Vol. SMC-8, No.1, janeiro de 1978, pp. 41-48.

APENDICE A

TABELAS E FIGURAS DOS RESULTADOS DESCRITOS NO CAPITULO 4

TABELAS

Evolução da matriz de classificação

Classificação pelo Método da Máxima Verossimilhança Gaussiana

TABELA A1: Matriz de confusão da classificação da imagem SIC pelo método da Máxima Verossimilhança Gaussiana

clas.	0	1	2	3
cla 0	0	0	0	0
cla 1	0	647	11	0
cla 2	0	13	605	30
cla 3	0	3	71	1120
total	0	663	687	1150

Taxa de pixels corretamente classificados : 0.9488
Somatório da diagonal 2372 :

TABELA A2: Matriz de confusão da classificação da imagem SIE pelo método da Máxima Verossimilhança Gaussiana

clas.	0	1	2	3
cla 0	0	0	0	0
cla 1	0	1028	26	3
cla 2	0	8	571	23
cla 3	0	0	67	774
total	0	1036	664	800

Somatório da diagonal : 2373
Taxa de pixels corretamente classificados : 0.9492

RELAXACAO PROBABILISTICA

TABELA A3: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Probabilística

Iteração : 1

clas.	0	1	2	3
cla 0	0	0	0	0
cla 1	0	652	6	0
cla 2	0	9	618	21
cla 3	0	0	55	1139
total	0	661	679	1160

Somatório da diagonal 2409
Taxa de pixels corretamente classificados : 0.9636

TABELA A4: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Probabilística

Iteração : 2

clas.	0	1	2	3
cla 0	0	0	0	0
cla 1	0	654	4	0
cla 2	0	3	628	17
cla 3	0	0	49	1145
total	0	657	681	1162

Somatório da diagonal 2427
Taxa de pixels corretamente classificados : 0.9708

TABELA A5: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Probabilística

Iteração : 3

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	655	3	0
cla 2	2	0	3	632	13
cla 3	3	0	0	38	1156
total		0	658	673	1169

Somatório da diagonal 2443

Taxa de pixels corretamente classificados : 0.9772

TABELA A6: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Probabilística

Iteração : 4

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	656	2	0
cla 2	2	0	3	634	11
cla 3	3	0	0	29	1165
total		0	659	665	1176

Somatório da diagonal 2455

Taxa de pixels corretamente classificados : 0.9820

TABELA A7: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Probabilística

Iteração : 5

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	656	2	0
cla 2	2	0	2	637	9
cla 3	3	0	0	21	1173
total		0	658	660	1182

Somatório da diagonal 2466

Taxa de pixels corretamente classificados : 0.9864

TABELA A8: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Probabilística

Iteração : 6

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	656	2	0
cla 2	2	0	2	637	9
cla 3	3	0	0	19	1175
total		0	658	658	1184

Somatório da diagonal 2468

Taxa de pixels corretamente classificados : 0.9872

TABELA A9: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Probabilística

Iteração : 7

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	656	2	0
cla 2	0	0	2	639	7
cla 3	0	0	0	17	1177
total		0	658	658	1184

Somatório da diagonal 2472

Taxa de pixels corretamente classificados : 0.9888

TABELA A10: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Probabilística

Iteração : 8

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	656	2	0
cla 2	0	0	2	641	5
cla 3	0	0	0	15	1179
total		0	658	658	1184

Somatório da diagonal 2476

Taxa de pixels corretamente classificados : 0.9904

TABELA A11: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Probabilística

Iteração : 9

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	656	2	0
cla 2	0	0	2	643	3
cla 3	0	0	0	13	1181
total		0	658	658	1184

Somatório da diagonal 2480

Taxa de pixels corretamente classificados : 0.9920

TABELA A12: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Probabilística

Iteração : 10

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	656	2	0
cla 2	0	0	2	643	3
cla 3	0	0	0	14	1180
total		0	658	659	1183

Somatório da diagonal 2479

Taxa de pixels corretamente classificados : 0.9916

TABELA A13: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Probabilística

Iteração : 1

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1038	17	2
cla 2	0	0	3	580	19
cla 3	0	0	0	59	782
Total		0	1041	656	803

Somatório da diagonal : 2400

Taxa de pixels corretamente classificados : 0.9600

TABELA A14: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Probabilística

Iteração : 2

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1043	13	1
cla 2	0	0	2	581	19
cla 3	0	0	0	53	788
Total		0	1045	647	808

Somatório da diagonal : 2412

Taxa de pixels corretamente classificados : 0.9648

TABELA A15: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Probabilística

Iteração : 3

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1044	12	1
cla 2	0	0	2	585	15
cla 3	0	0	0	46	795
Total		0	1046	643	811

Somatório da diagonal : 2424

Taxa de pixels corretamente classificados : 0.9696

TABELA A16: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Probabilística

Iteração : 4

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1045	11	1
cla 2	0	0	2	586	14
cla 3	0	0	0	41	800
Total		0	1047	638	815

Somatório da diagonal : 2431

Taxa de pixels corretamente classificados : 0.9724

TABELA A17: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Probabilística

Iteração : 5

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1047	9	1
cla 2	0	0	2	586	14
cla 3	0	0	0	34	807
Total		0	1049	629	822

Somatório da diagonal : 2440

Taxa de pixels corretamente classificados : 0.9760

TABELA A18: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Probabilística

Iteração : 6

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1047	9	1
cla 2	0	0	2	589	11
cla 3	0	0	0	28	813
Total		0	1049	626	825

Somatório da diagonal : 2449

Taxa de pixels corretamente classificados : 0.9796

TABELA A19: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Probabilística

Iteração : 7

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1047	9	1
cla 2	0	0	1	591	10
cla 3	0	0	0	24	817
Total		0	1048	624	828

Somatório da diagonal : 2455

Taxa de pixels corretamente classificados : 0.9820

TABELA A20: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Probabilística

Iteração : 8

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1047	9	1
cla 2	0	0	1	592	9
cla 3	0	0	0	23	818
Total		0	1048	624	828

Somatório da diagonal : 2457

Taxa de pixels corretamente classificados : 0.9828

TABELA A21: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Probabilística

Iteração : 9

clas.		0	1	2	3
cla 0		0	0	0	0
cla 1		0	1047	9	1
cla 2		0	1	592	9
cla 3		0	0	21	820
Total		0	1048	622	830

Somatório da diagonal : 2459

Taxa de pixels corretamente classificados : 0.9836

TABELA A22: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Probabilística

Iteração : 10

clas.		0	1	2	3
cla 0		0	0	0	0
cla 1		0	1047	9	1
cla 2		0	1	592	9
cla 3		0	0	18	823
Total		0	1048	619	833

Somatório da diagonal : 2462

Taxa de pixels corretamente classificados : 0.9848

Processo de Relaxação Fuzzy

TABELA A23: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Fuzzy

Iteração : 1
Limiares(0.4 , 0.5)

clas.		0	1	2	3
cla 0		0	0	0	0
cla 1		0	631	27	0
cla 2		0	9	602	37
cla 3		0	6	108	1080
Total		0	646	737	1117

Somatorio da diagonal : 2313

Taxa de pixels corretamente classificados : 0.9252

TABELA A24: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Fuzzy

Iteração : 2
Limiares (0.3 , 0.5)

clas.		0	1	2	3
cla 0		0	0	0	0
cla 1		0	599	59	0
cla 2		0	16	575	57
cla 3		0	6	203	985
Total		0	621	837	1042

Somatorio da diagonal : 2159

Taxa de pixels corretamente classificados : 0.8636

TABELA A25: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Fuzzy

Iteração : 3 Limiares (0.2 , 0.5)

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	564	94	0
cla 2	0	0	19	558	71
cla 3	0	0	6	254	934
Total		0	589	906	1005

Somatorio da diagonal : 2056

Taxa de pixels corretamente classificados : 0.8224

TABELA A26: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Fuzzy

Iteração : 4 Limiares (0.15 , 0.5)

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	537	121	0
cla 2	0	0	22	555	71
cla 3	0	0	6	275	913
Total		0	565	951	984

Somatorio da diagonal : 2005

Taxa de pixels corretamente classificados : 0.8020

TABELA A27: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Fuzzy

Iteração : 1 Limiares (0.4 , 0.5)

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	988	68	1
cla 2	0	0	7	574	21
cla 3	0	0	3	137	701
Total		0	998	779	723

Somatorio da diagonal : 2263

Taxa de pixels corretamente classificados : 0.9052

TABELA A28: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Fuzzy

Iteração : 2 Limiares (0.3 , 0.5)

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	941	116	0
cla 2	0	0	9	564	29
cla 3	0	0	3	222	616
Total		0	953	902	645

Somatorio da diagonal : 2121

Taxa de pixels corretamente classificados : 0.8484

TABELA A29: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Fuzzy

Iteração : 3
Limiares (0.2 , 0.5)

clas.	0	1	2	3
cla 0	0	0	0	0
cla 1	0	895	162	0
cla 2	0	11	554	37
cla 3	0	3	243	595
Total	0	909	959	632

Somatorio da diagonal : 2044

Taxa de pixels corretamente classificados : 0.8176

TABELA A30: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Fuzzy

Iteração : 3
Limiares (0.15 , 0.5)

clas.	0	1	2	3
cla 0	0	0	0	0
cla 1	0	870	187	0
cla 2	0	14	545	43
cla 3	0	3	246	592
Total	0	887	978	635

Somatorio da diagonal : 2007

Taxa de pixels corretamente classificados : 0.8028

Processo de Relaxação Fuzzy Modificado Com a Média

TABELA A31: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Fuzzy. Limiares: Média, 0.5

Iteração : 1

clas.	0	1	2	3
cla 0	0	0	0	0
cla 1	0	648	10	0
cla 2	0	4	638	6
cla 3	0	6	19	1169
Total	0	658	667	1175

Somatorio da diagonal : 2455

Taxa de pixels corretamente classificados : 0.9820

TABELA A32: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Fuzzy

Iteração : 2

clas.	0	1	2	3
cla 0	0	0	0	0
cla 1	0	644	14	0
cla 2	0	7	627	14
cla 3	0	6	23	1165
Total	0	657	664	1179

Somatorio da diagonal : 2436

Taxa de pixels corretamente classificados : 0.9744

TABELA A33: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Fuzzy

Iteração : 3

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	641	17	0
cla 2	0	0	7	624	17
cla 3	0	0	6	25	1163
Total		0	654	666	1180

Somatorio da diagonal : 2428

Taxa de pixels corretamente classificados : 0.9712

TABELA A34: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Fuzzy

Iteração : 4

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	640	18	0
cla 2	0	0	7	623	18
cla 3	0	0	5	23	1166
Total		0	652	664	1184

Somatorio da diagonal : 2429

Taxa de pixels corretamente classificados : 0.9716

TABELA A35: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Fuzzy

Iteração : 5

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	640	18	0
cla 2	0	0	7	623	18
cla 3	0	0	5	22	1167
Total		0	652	663	1185

Somatorio da diagonal : 2430

Taxa de pixels corretamente classificados : 0.9720

TABELA A36: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Fuzzy

Iteração : 6

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	639	19	0
cla 2	0	0	7	624	17
cla 3	0	0	4	22	1168
Total		0	650	665	1185

Somatorio da diagonal : 2431

Taxa de pixels corretamente classificados : 0.9724

TABELA A37: Matriz de confusão da classificação da imagem SIC pelo método da Relaxação Fuzzy

Iteração : 7

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	639	19	0
cla 2	0	0	8	621	19
cla 3	0	0	4	22	1168
Total		0	651	662	1187

Somatorio da diagonal : 2428

Taxa de pixels corretamente classificados : 0.9712

TABELA A38: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Fuzzy

Iteração : 1

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1024	32	1
cla 2	0	0	5	588	9
cla 3	0	0	3	45	793
Total		0	1032	665	803

Somatorio da diagonal : 2405

Taxa de pixels corretamente classificados : 0.9620

TABELA A39: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Fuzzy

Iteração : 2

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1020	36	1
cla 2	0	0	5	585	12
cla 3	0	0	3	56	782
Total		0	1028	677	795

Somatorio da diagonal : 2387

Taxa de pixels corretamente classificados : 0.9548

TABELA A40: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Fuzzy

Iteração : 3

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1018	38	1
cla 2	0	0	5	583	14
cla 3	0	0	3	58	780
Total		0	1026	679	795

Somatorio da diagonal : 2381

Taxa de pixels corretamente classificados : 0.9524

TABELA A41: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Fuzzy

Iteração : 4

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	1016	40	1
cla 2	2	0	6	582	14
cla 3	3	0	2	54	785
Total		0	1024	676	800

Somatorio da diagonal : 2383

Taxa de pixels corretamente classificados : 0.9532

TABELA A42: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Fuzzy

Iteração : 5

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	1017	39	1
cla 2	2	0	6	581	15
cla 3	3	0	2	55	784
Total		0	1025	675	800

Somatorio da diagonal : 2382

Taxa de pixels corretamente classificados : 0.9528

TABELA A43: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Fuzzy

Iteração : 6

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	1017	39	1
cla 2	2	0	6	578	18
cla 3	3	0	2	57	782
Total		0	1025	674	801

Somatorio da diagonal : 2377

Taxa de pixels corretamente classificados : 0.9508

TABELA A44: Matriz de confusão da classificação da imagem SIE pelo método da Relaxação Fuzzy

Iteração : 7

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	1016	40	1
cla 2	2	0	6	578	18
cla 3	3	0	1	57	783
Total		0	1023	675	802

Somatorio da diagonal : 2377

Taxa de pixels corretamente classificados : 0.9508

Processo Combinado de Filtragem Espacial e Relaxação Probabilística
TABELA A45: Matriz de confusão da classificação da imagem SIC pelo método combinado de filtragem espacial e Relaxação Probabilística

		Filtragem espacial			
clas.		0	1	2	3
cla	0	0	0	0	0
cla	1	0	605	2	51
cla	2	0	0	581	67
cla	3	0	0	5	1189
Total		0	605	588	1307

Somatorio da diagonal : 2375

Taxa de pixels corretamente classificados : 0.9500

TABELA A46: Matriz de confusão da classificação da imagem SIC pelo método combinado de filtragem espacial e Relaxação Probabilística

		Iteração 1			
clas.		0	1	2	3
cla	0	0	0	0	0
cla	1	0	648	4	6
cla	2	0	1	645	2
cla	3	0	0	6	1188
Total		0	649	655	1196

Somatorio da diagonal : 2481

Taxa de pixels corretamente classificados : 0.9924

TABELA A47: Matriz de confusão da classificação da imagem SIE pelo método combinado de filtragem espacial e Relaxação Probabilística

		Filtragem Espacial			
clas.		0	1	2	3
cla	0	0	0	0	0
cla	1	0	942	6	109
cla	2	0	1	537	64
cla	3	0	0	4	837
Total		0	943	547	1010

Somatorio da diagonal : 2316

Taxa de pixels corretamente classificados : 0.9264

TABELA A48: Matriz de confusão da classificação da imagem SIE pelo método combinado de filtragem espacial e relaxação Probabilística

		Iteração 1			
clas.		0	1	2	3
cla	0	0	0	0	0
cla	1	0	1047	6	4
cla	2	0	4	593	5
cla	3	0	0	5	836
Total		0	1051	604	845

Somatorio da diagonal : 2476

Taxa de pixels corretamente classificados : 0.9904

TABELA A49: Matriz de confusão da classificação da imagem SIE pelo método combinado de filtragem espacial e relaxação Probabilística Relaxação Probabilística (caso 1) Iteração 2

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1046	6	5
cla 2	0	0	3	594	5
cla 3	0	0	0	6	835
Total		0	1049	606	845

Somatorio da diagonal : 2475

Taxa de pixels corretamente classificados : 0.9900

TABELA A50: Matriz de confusão da classificação da imagem SIE pelo método combinado de filtragem espacial e relaxação Probabilística Relaxação Probabilística (caso 2) Iteração 1

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1047	6	4
cla 2	0	0	4	593	5
cla 3	0	0	0	5	836
Total		0	1051	604	845

Somatorio da diagonal : 2476

Taxa de pixels corretamente classificados : 0.9904

TABELA A51: Matriz de confusão da classificação da imagem SIE pelo método combinado de filtragem espacial e relaxação Probabilística Relaxação Probabilística (caso 2) Iteração 2

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1047	6	4
cla 2	0	0	3	594	5
cla 3	0	0	0	6	835
Total		0	1050	606	844

Somatorio da diagonal : 2476

Taxa de pixels corretamente classificados : 0.9904

Processo Combinado de Relaxação Probabilística e Fuzzy

TABELA A52: Matriz de confusão da classificação da imagem SIC pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy Relaxação Probabilística Iteração 1

clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	652	6	0
cla 2	0	0	9	618	21
cla 3	0	0	0	55	1139
Total		0	661	679	1160

Somatorio da diagonal 2409 :

taxa de pixels corretamente classificados : 0.9636

TABELA A53: Matriz de confusão da classificação da imagem SIC pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Probabilística		Iteração 2			
clas.		0	1	2	3
cla	0	0	0	0	0
cla	1	0	654	4	0
cla	2	0	3	628	17
cla	3	0	0	49	1145
Total		0	657	681	1162

Somatorio da diagonal 2427 :

taxa de pixels corretamente classificados : 0.9708

TABELA A54: Matriz de confusão da classificação da imagem SIC pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Probabilística		Iteração 3			
clas.		0	1	2	3
cla	0	0	0	0	0
cla	1	0	655	3	0
cla	2	0	3	632	13
cla	3	0	0	38	1156
Total		0	658	673	1169

Somatorio da diagonal 2443 :

taxa de pixels corretamente classificados : 0.9772

TABELA A55: Matriz de confusão da classificação da imagem SIC pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Probabilística		Iteração 4			
clas.		0	1	2	3
cla	0	0	0	0	0
cla	1	0	656	2	0
cla	2	0	3	634	11
cla	3	0	0	29	1165
Total		0	659	665	1176

Somatorio da diagonal 2455 :

taxa de pixels corretamente classificados : 0.9820

TABELA A56: Matriz de confusão da classificação da imagem SIC pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Fuzzy		Iteração 1			Limiares (0.4/0.5)
clas.		0	1	2	3
cla	0	0	0	0	0
cla	1	0	640	12	6
cla	2	0	5	627	16
cla	3	0	0	44	1150
Total		0	645	683	1172

Somatorio da diagonal : 2417

Taxa de pixels corretamente classificados : 0.9668

TABELA A57: Matriz de confusão da classificação da imagem SIC pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Fuzzy		Iteração 6			
		Limiares (0.3/0.5)			
clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	640	12	6
cla 2	2	0	5	623	20
cla 3	3	0	0	65	1129
Total		0	645	700	1155

Somatorio da diagonal : 2392

Taxa de pixels corretamente classificados : 0.9568

TABELA A58: Matriz de confusão da classificação da imagem SIC pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Fuzzy		Iteração 7			
		Limiares (0.2/0.5)			
clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	640	12	6
cla 2	2	0	6	620	22
cla 3	3	0	0	93	1101
Total		0	646	725	1129

Somatorio da diagonal : 2361

Taxa de pixels corretamente classificados : 0.9444

TABELA A59: Matriz de confusão da classificação da imagem SIC pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Fuzzy		Iteração 8			
		Limiares (0.15/0.5)			
clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	640	12	6
cla 2	2	0	7	613	28
cla 3	3	0	0	120	1074
Total		0	647	745	1108

Somatorio da diagonal : 2327

Taxa de pixels corretamente classificados : 0.9308

TABELA A60: Matriz de confusão da classificação da imagem SIE pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Probabilística		Iteração 1			
clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	1038	17	2
cla 2	2	0	3	580	19
cla 3	3	0	0	59	782
Total		0	1041	656	803

Somatorio da diagonal : 2400

Taxa de pixels corretamente classificados : 0.9600

TABELA A61: Matriz de confusão da classificação da imagem SIE pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Probabilística		Iteração 2			
clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	1043	13	1
cla 2	2	0	2	581	19
cla 3	3	0	0	53	788
Total		0	1045	647	808

Somatorio da diagonal : 2412

Taxa de pixels corretamente classificados : 0.9648

TABELA A62: Matriz de confusão da classificação da imagem SIE pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Probabilística		Iteração 3			
clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	1044	12	1
cla 2	2	0	2	585	15
cla 3	3	0	0	46	795
Total		0	1046	643	811

Somatorio da diagonal : 2424

Taxa de pixels corretamente classificados : 0.9696

TABELA A63: Matriz de confusão da classificação da imagem SIE pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Probabilística		Iteração 4			
clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	1045	11	1
cla 2	2	0	2	586	14
cla 3	3	0	0	41	800
Total		0	1047	638	815

Somatorio da diagonal : 2431

Taxa de pixels corretamente classificados : 0.9724

TABELA A64: Matriz de confusão da classificação da imagem SIE pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Fuzzy		Iteração 5 Limiares (0.4/0.5)			
clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	1	0	1029	25	3
cla 2	2	0	5	579	18
cla 3	3	0	0	63	778
Total		0	1034	667	799

Somatorio da diagonal : 2386

Taxa de pixels corretamente classificados : 0.9544

TABELA A65: Matriz de confusão da classificação da imagem SIE pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Fuzzy		Iteração 6			
		Limiares (0.3/0.5)			
clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1027	27	3
cla 2	0	0	6	575	21
cla 3	0	0	0	95	746
Total		0	1033	697	770

Somatorio da diagonal : 2348

Taxa de pixels corretamente classificados : 0.9392

TABELA A66: Matriz de confusão da classificação da imagem SIE pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Fuzzy		Iteração 7			
		Limiares (0.2/0.5)			
clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1027	27	3
cla 2	0	0	6	572	24
cla 3	0	0	0	107	734
Total		0	1033	706	761

Somatorio da diagonal : 2333

Taxa de pixels corretamente classificados : 0.9332

TABELA A67: Matriz de confusão da classificação da imagem SIE pelo método combinado de Relaxação Probabilística e Relaxação Fuzzy

Relaxação Fuzzy		Iteração 8			
		Limiares (0.15/0.5)			
clas.		0	1	2	3
cla 0	0	0	0	0	0
cla 1	0	0	1027	27	3
cla 2	0	0	7	567	28
cla 3	0	0	0	118	723
Total		0	1034	712	754

Somatorio da diagonal : 2317

Taxa de pixels corretamente classificados : 0.9268

TABELA A68: Taxa de pixels corretamente classificado, taxa média de variação e entropia. Relaxação Probabilística aplicada à imagem SIC

i	Taxa média de variação	Entropia	Taxa de pixels corretos %
0			94.88
1	0.037611	0.074862	96.36
2	0.024634	0.058601	97.08
3	0.018255	0.046644	97.72
4	0.013780	0.037628	98.20
5	0.010560	0.030765	98.64
6	0.008102	0.025479	98.72
7	0.006333	0.021333	98.88
8	0.004938	0.018178	99.04
9	0.003852	0.015581	99.20
1	0.002916	0.013577	99.16

TABELA A69: Taxa média de variação, entropia e taxa de pixels corretamente classificados. Relaxação Probabilística aplicada à imagem SIE

i	Taxa média de variação	Entropia	Taxa de pixels corretos %
0		0.084465	94.92
1	0.029327	0.064964	96.00
2	0.020440	0.051460	96.48
3	0.014752	0.041473	96.96
4	0.011019	0.034528	97.24
5	0.008691	0.029526	97.60
6	0.007110	0.025765	97.96
7	0.005869	0.022623	98.20
8	0.004899	0.019983	98.28
9	0.003995	0.017762	98.36
10	0.003334	0.015738	98.48

TABELA A70: Taxa média de variação, entropia e taxa de pixels corretamente classificados. Relaxação Fuzzy aplicada à imagem SIC

i	Taxa média de variação	entropia	Taxa pixels corretos %	limiares
0		0.101183	94.88	
1	0.127848	0.135284	92.52	0.40/0.5
2	0.124488	0.176898	86.36	0.30/0.5
3	0.124590	0.197944	82.24	0.30/0.5
4	0.120239	0.202745	80.20	0.15/0.5

TABELA A71: Taxa média de variação, entropia e taxa de pixels corretamente classificados. Relaxação Fuzzy aplicada à imagem SIE

i	Taxa m. variação	Entropia	Taxa de pixels corretos (%)	limiares
0		0.084465	94.92	
1	0.307438	0.110628	90.52	0.40/0.5
2	0.299518	0.147564	84.84	0.30/0.5
3	0.298606	0.165859	81.76	0.20/0.5
4	0.296834	0.176045	80.28	0.15/0.5

TABELA A72: Taxa média de variação, entropia e taxa de pixels corretamente classificados para o processo combinado de Relaxação Probabilística e Fuzzy aplicado à imagem SIC

i	Taxa média de variação	Entropia	Taxa de pixels corretos %
0			94.88
1	0.037611	0.074862	96.36
2	0.024634	0.058601	97.08
3	0.018255	0.046644	97.72
4	0.013780	0.037628	98.20
5	0.207993	0.044322	96.68
6	0.200122	0.068211	95.68
7	0.199362	0.089831	94.44
8	0.198492	0.105557	93.08

TABELA A73: Taxa média de variação, entropia e taxa de pixels corretamente classificados para o processo combinado de Relaxação Probabilística e Fuzzy aplicado à imagem SIE

i	Taxa média de variação	entropia	Taxa de pixels corretos %
0		0.084465	94.92
1	0.029327	0.064964	96.00
2	0.020440	0.051460	96.48
3	0.014752	0.041473	96.96
4	0.011019	0.034528	97.24
5	0.292276	0.044700	95.44
6	0.279621	0.064165	93.92
7	0.277240	0.080722	93.32
8	0.276995	0.095456	92.68

TABELA A74: Taxa média de variação, entropia e taxa de pixels corretamente classificados para o processo de Relaxação Fuzzy modificada com a média local aplicado à imagem SIC

i	Taxa média de variação	Entropia	Taxa de pixels corretos %
0		0.101183	94.88
1	0.285694	0.112373	98.20
2	0.286826	0.138633	97.44
3	0.287749	0.164948	97.12
4	0.287752	0.190149	97.16
5	0.287752	0.212954	97.20
6	0.287851	0.233172	97.24
7	0.287851	0.251686	97.12

TABELA A75: Taxa média de variação, entropia e taxa de pixels corretamente classificados para o processo de Relaxação Fuzzy modificada com a média local aplicado à imagem SIE

i	Taxa média de variação	Entropia	Taxa de pixels corretos %
0			94.92
1	0.247828	0.100091	96.20
2	0.248330	0.129397	95.48
3	0.248984	0.155619	95.24
4	0.249358	0.178463	95.32
5	0.249358	0.197015	95.28
6	0.249358	0.242035	95.08
7	0.249358	0.225545	95.08

TABELA A76: Taxa de pixels corretamente classificados no teste do processo combinado de Relaxação Probabilística e Filtragem Espacial aplicado à imagem SIC

Processamento	Taxa de pixels corretos(%)
Máx. Ver. Gauss	95.32
Filtro 1	95.60
Filtro 1 (2 vezes)	95.36
Filtro 2	96.08
Filtro 3	97.72
Filtro 4	97.08

TABELA A77: Entropia e Taxa de pixels corretamente classificados para o processo combinado de Relaxação Probabilística e Fuzzy aplicado à imagem SIC

Tipo de processamento	entropia	Taxa de pixels corretos %
Máxima. Verossimilhança G.	0.101183	94.88
Filtragem espacial	0.252856	95.00
Relaxação Probabilística	0.060015	99.24

TABELA A78: Entropia e taxa de pixels corretamente classificados no processo combinado de Relaxação Probabilística e Fuzzy aplicado à imagem SIE

Tipo de processamento	Taxa de pixels corretos (%)
Máx. Ver. G.	94.92
Filtragem	92.64
Rel. Probabilística caso 1	
1a. iteração	99.04
2a. iteração	99.04
Rel. Probabilística caso 2	
1a. iteração	99.04
2a. iteração	99.04

TABELA A79: Taxa média de variação e entropia Relaxação Probabilística aplicada à imagem Potiribú 1

iteração	Entropia	Taxa média de variação
0	0.098159	
1	0.091244	0.012992
2	0.087283	0.009877
3	0.083668	0.009372
4	0.080357	0.008989
5	0.077094	0.008547
8	0.067472	0.006616
10	0.062647	0.005661
15	0.052825	0.004278
20	0.044629	0.003292
22	0.041802	0.002889

TABELA A80: Taxa média de variação e entropia Relaxação Probabilística aplicada à imagem Potiribú 2

iteração	Entropia	Taxa média de variação
1	0.051153	0.008907
2	0.047112	0.006840
3	0.043663	0.005957
4	0.040770	0.005188
5	0.038213	0.004698
6	0.036098	0.004263
7	0.034183	0.003957
8	0.032562	0.003658
9	0.031003	0.003411
10	0.029480	0.003190
11	0.028018	0.002949
12	0.026536	0.002676
13	0.025163	0.002403
14	0.023864	0.002143
15	0.022647	0.001927

FIGURAS

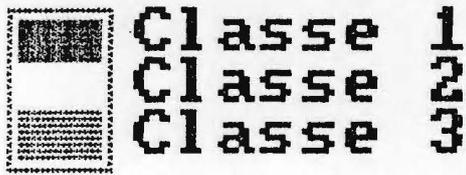
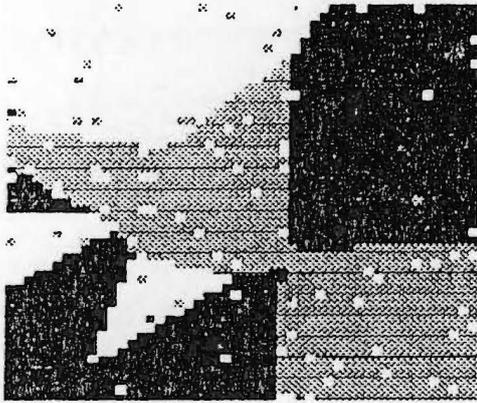


FIGURA A1: Imagem temática SIE após a classificação pelo método da Máxima Verossimilhança Gaussiana.

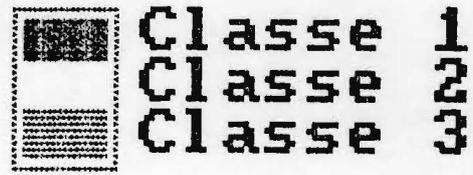
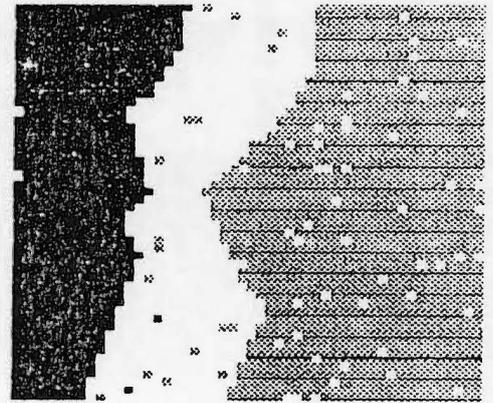
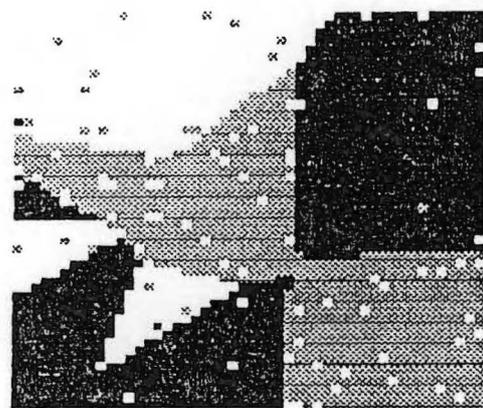
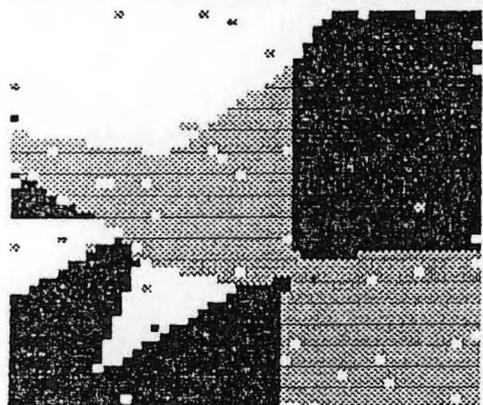


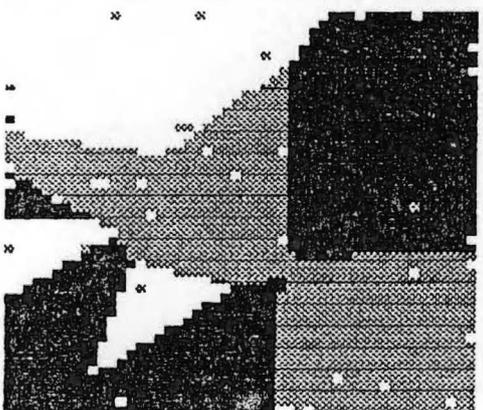
FIGURA A2: Imagem temática SIC após a classificação pelo método da Máxima Verossimilhança Gaussiana.



a



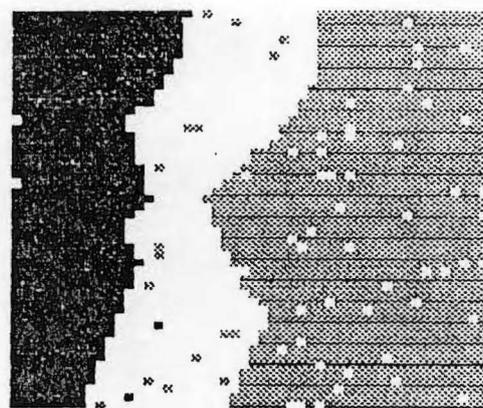
b



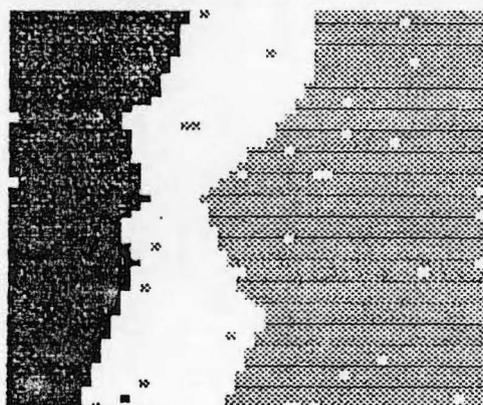
c



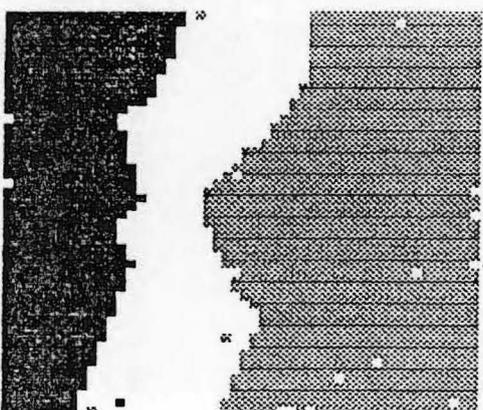
Classe 1
Classe 2
Classe 3



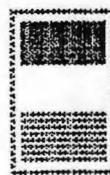
a



b



c



Classe 1
Classe 2
Classe 3

FIGURA A3: Imagem temática SIE durante o processo da relaxação probabilística.

(a) Após 2 iterações
(b) Após 6 iterações
(c) Após 10 iterações

FIGURA A4: Imagem temática SIE durante o processo da relaxação probabilística.

(a) Após 2 iterações
(b) Após 5 iterações
(c) Após 10 iterações

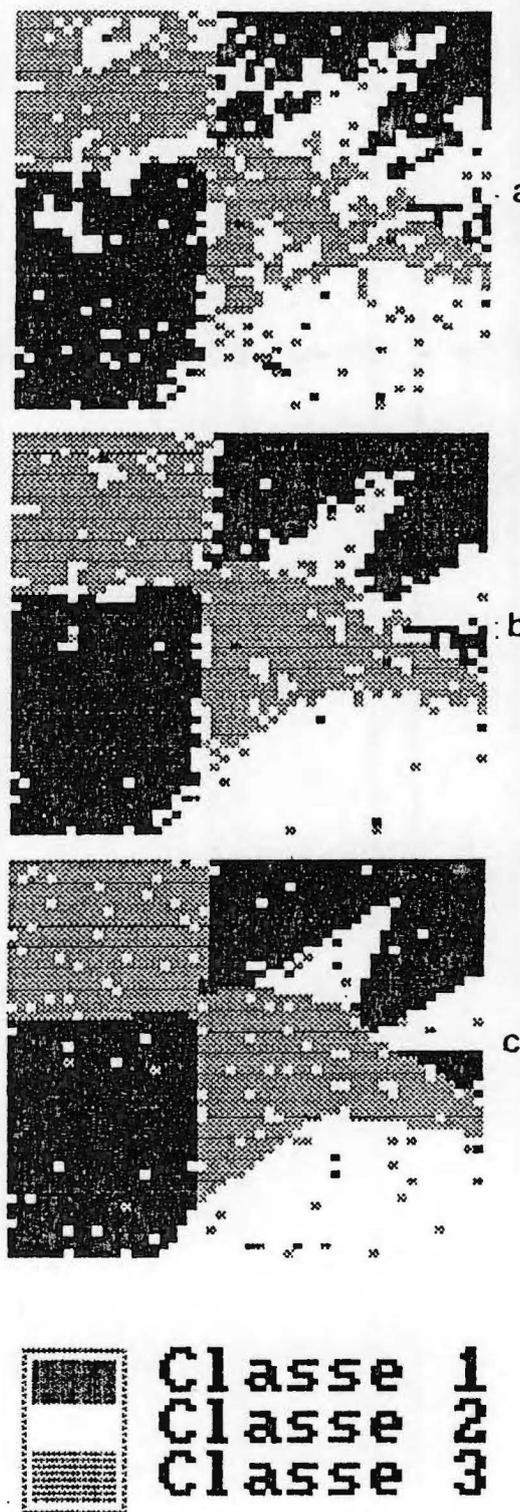


FIGURA A5: Imagem temática SIE durante o processo de relaxação fuzzy
 (a) Após Máxima Verossimilhança Gaussiana
 (b) Após 1 iteração
 (c) Após 4 iterações

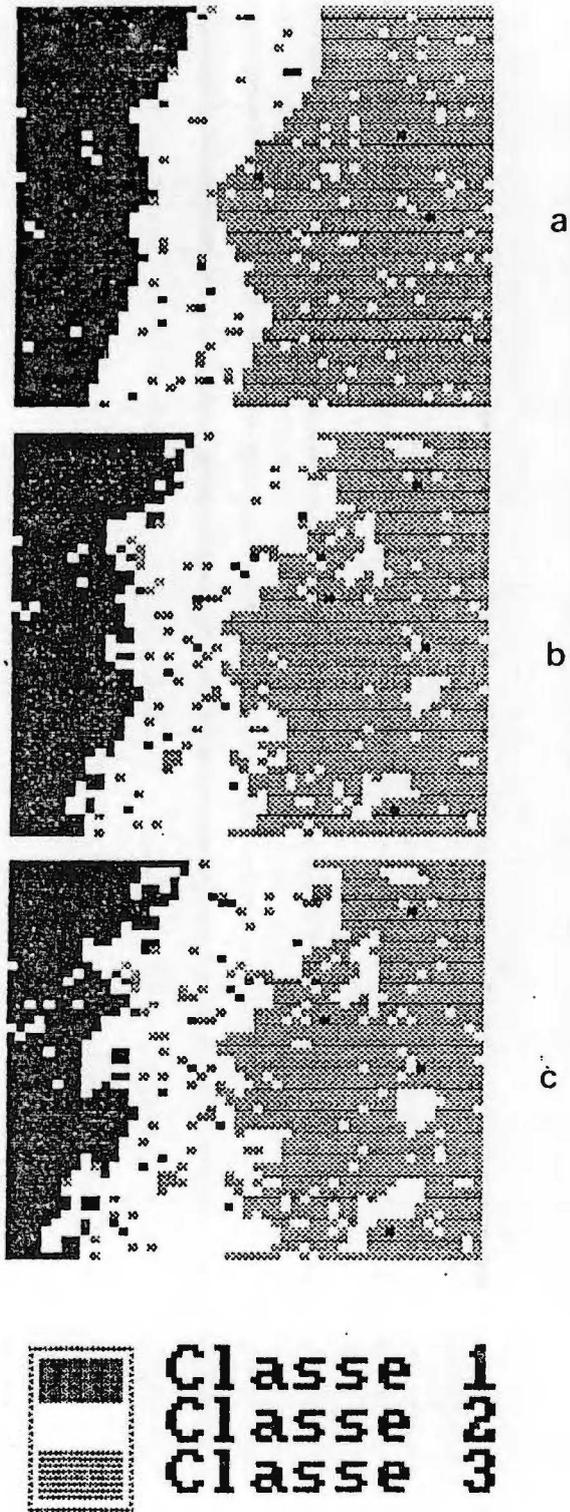


FIGURA A6: Imagem temática SIC durante o processo de relaxação fuzzy
 (a) Após Máxima Verossimilhança Gaussiana
 (b) Após 1 iteração
 (c) Após 4 iterações

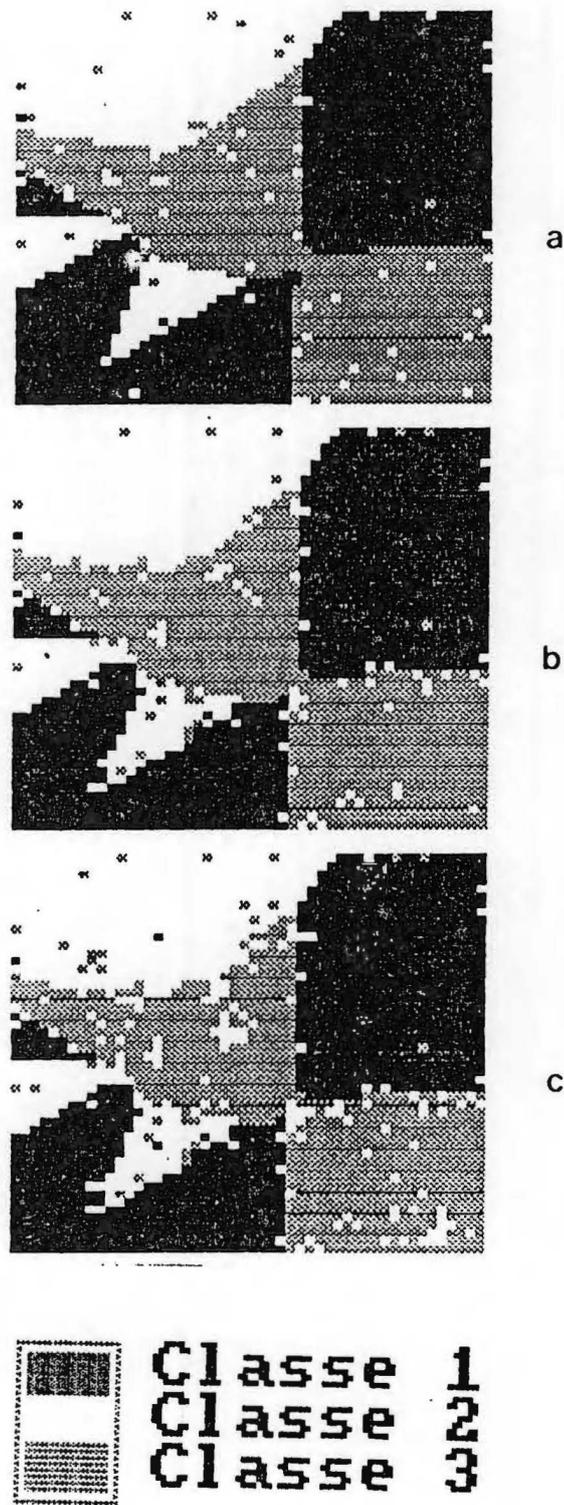


FIGURA A7: Imagem temática SIE durante o processo de relaxação fuzzy modificado com a média.
 (a) Após 1 iterações
 (b) Após 4 iterações
 (c) Após 7 iterações

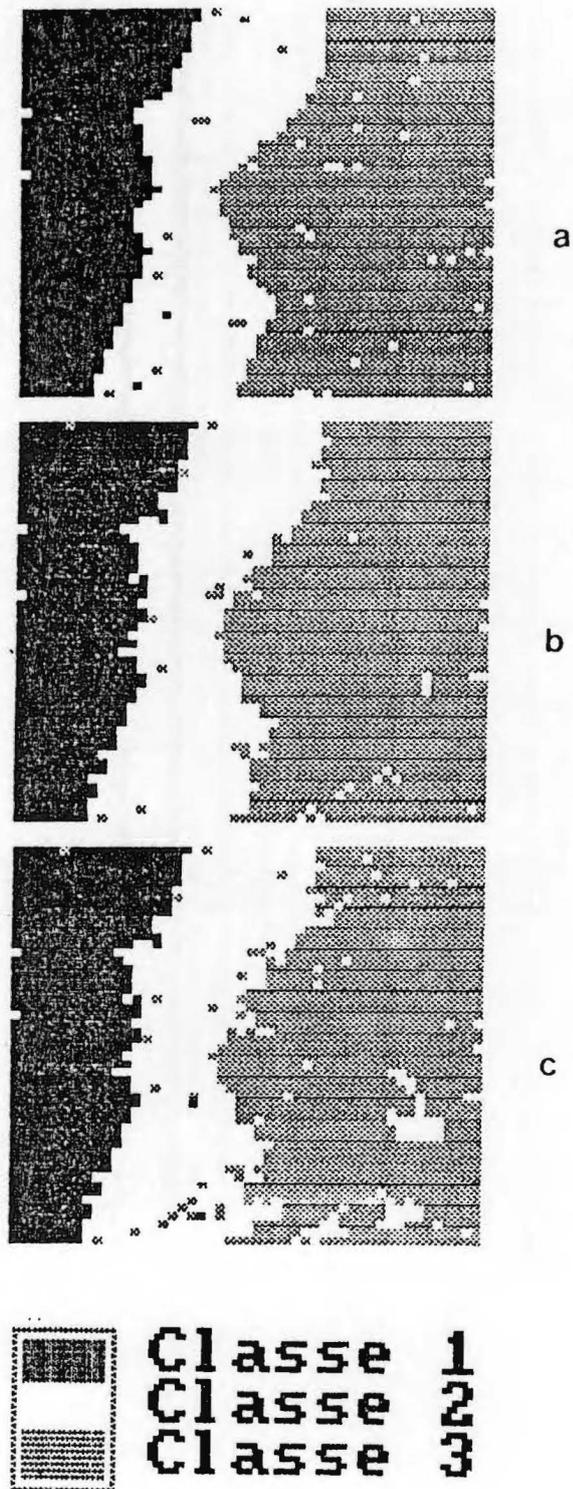


FIGURA A8: Imagem temática SIC durante o processo de relaxação fuzzy modificado com a média.
 (a) Após 1 iterações
 (b) Após 5 iterações
 (c) Após 7 iterações

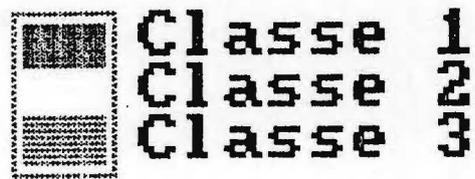
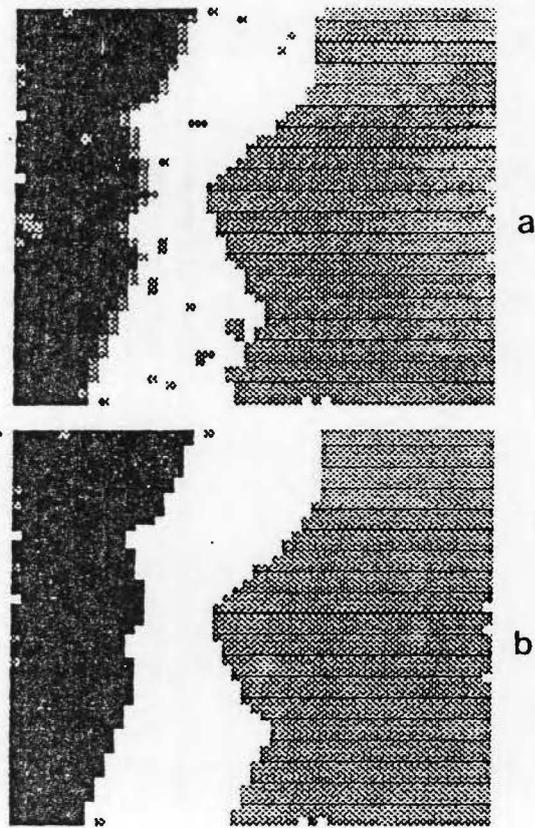


FIGURA A9: Imagem temática SIE do teste do processo combinado de filtragem espacial e relaxação probabilística.

- (a) Após a filtragem espacial
- (b) Após a relaxação probabilística

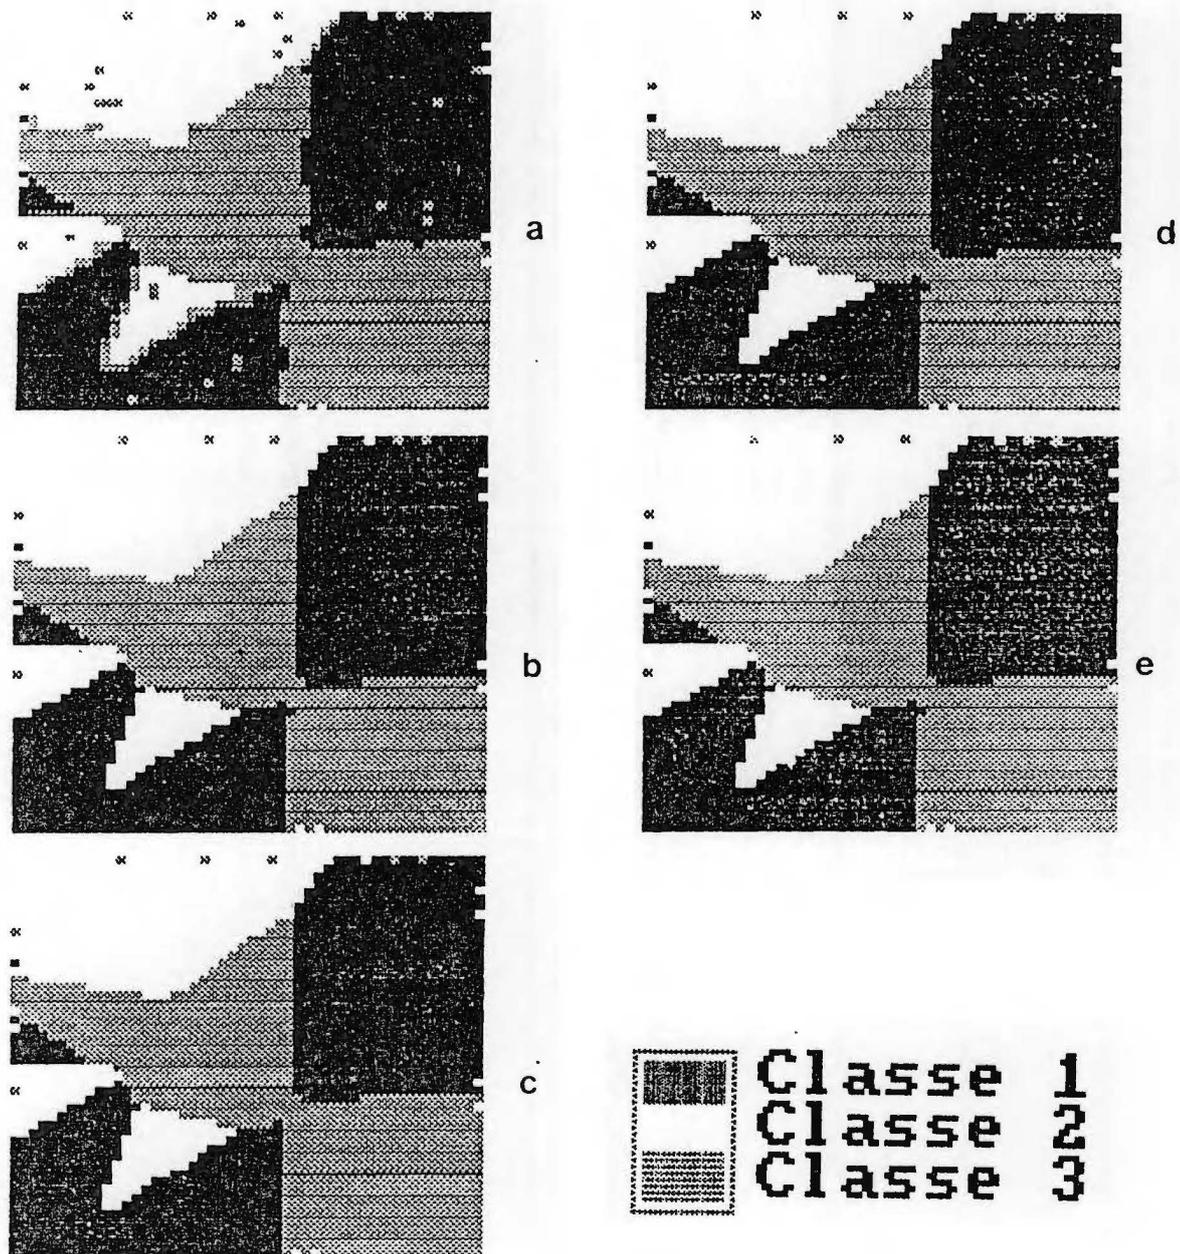


FIGURA A10: Imagem temática SIE durante o processo combinado de filtragem espacial e relaxação probabilística

(a) Após a filtragem espacial

(b) Após 1 iteração da relaxação probabilística caso 1

(c) Após 2 iterações da relaxação probabilística caso 1

(d) Após 1 iteração da relaxação probabilística caso 2

(e) Após 2 iterações da relaxação probabilística caso 2

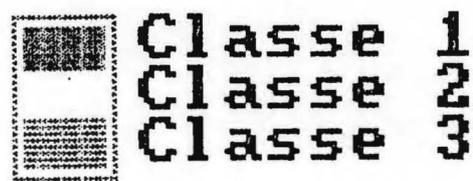
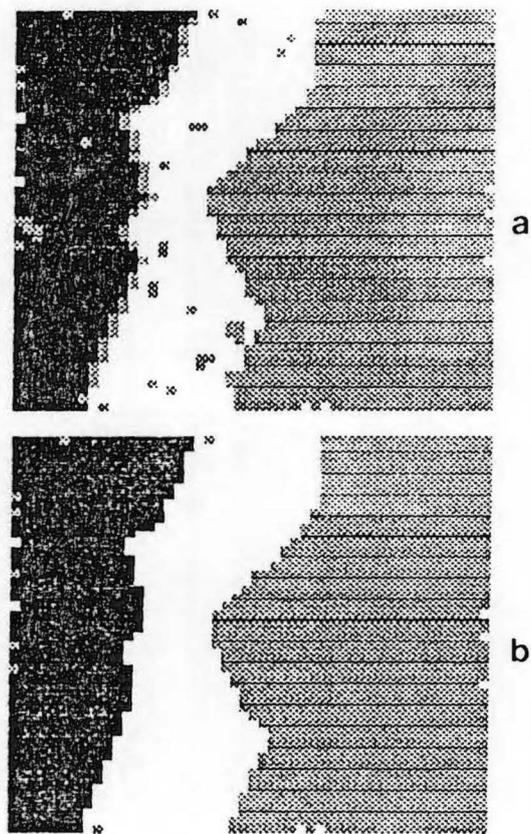


FIGURA A11: Imagem temática SIC durante o processo combinado de filtragem espacial e relaxação probabilística
 (a) Após a filtragem espacial
 (b) Após 1 iteração da relaxação probabilística

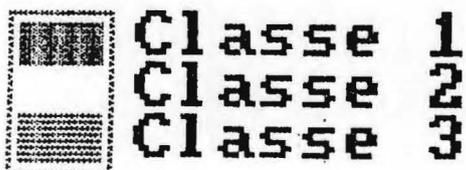
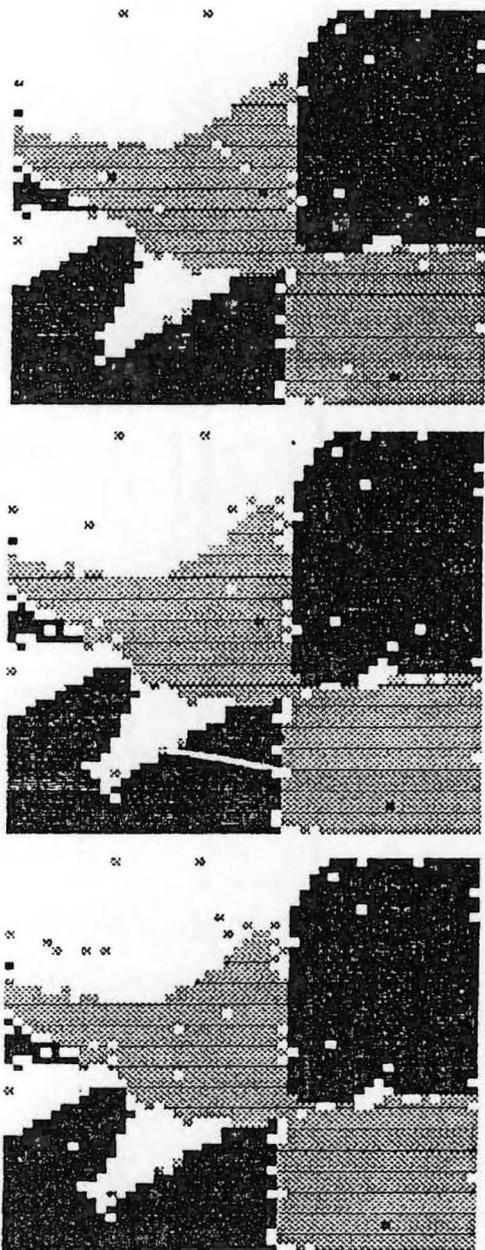


FIGURA A12: Imagen temática SIE durante o processo combinado de relaxação probabilística (R.P.) e relaxação fuzzy (R.F.).
 (a) Após 4 (R.P.) e 1 (R.F.)
 (b) Após 4 (R.P.) e 2 (R.F.)
 (c) Após 4 (R.P.) e 4 (R.F.)

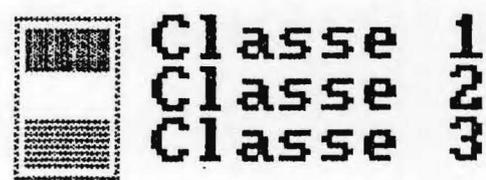
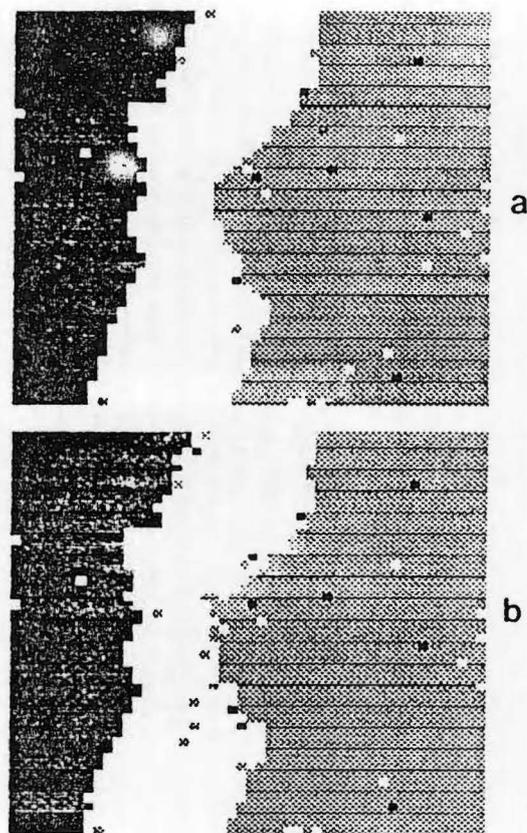


FIGURA A13: Imagen temática SIE durante o processo combinado de relaxação probabilística (R.P.) e relaxação fuzzy (R.F.).
 (a) Após 4 (R.P.) e 1 (R.F.)
 (b) Após 4 (R.P.) e 4(R.F.)

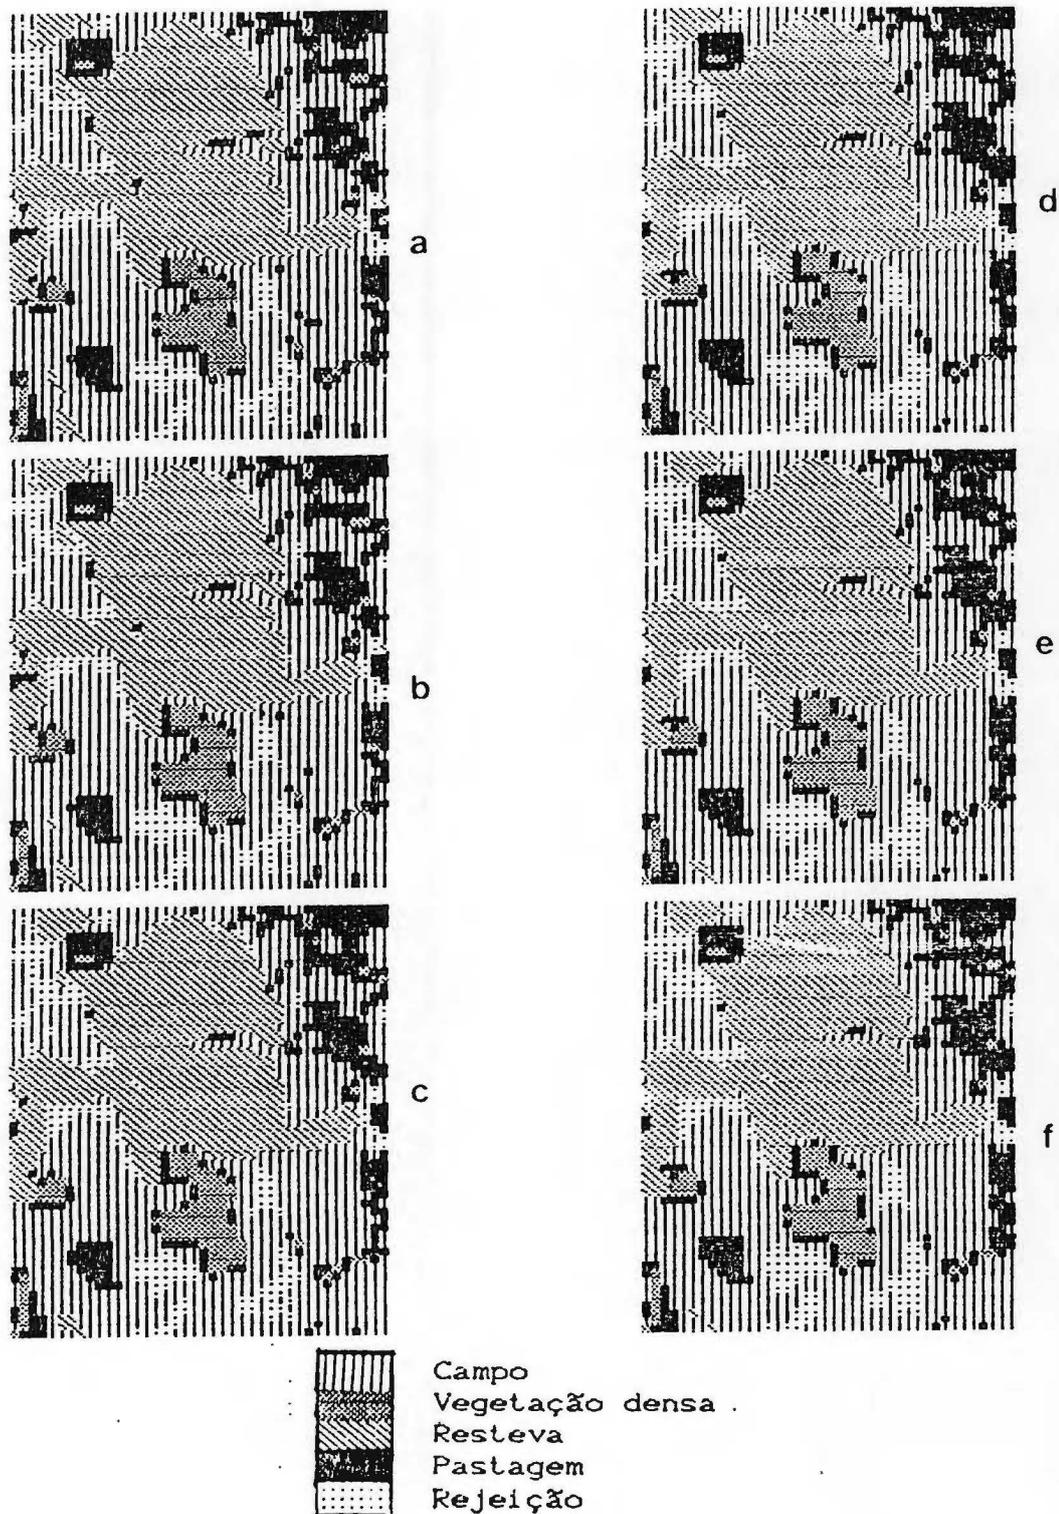


FIGURA A14: imagem temática Potiribú-1 durante o processo de relaxação probabilística.

- (a) Após a M.V.G. (b) Após 3 iterações
 (c) Após 10 iterações (d) Após 15 iterações
 (e) Após 20 iterações (f) Após 30 iterações

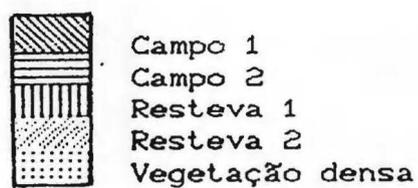
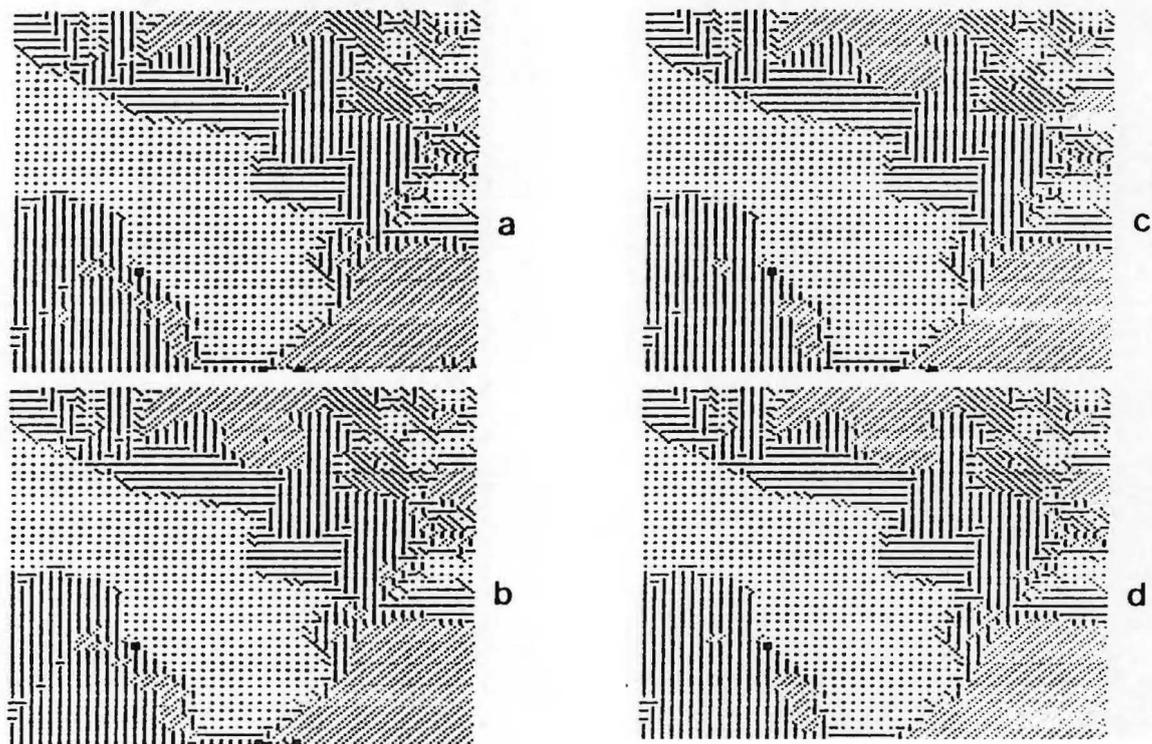


FIGURA A15: imagem temática Potiribú-2 durante o processo de relaxação probabilística.

(a) Após a M.V.G. (b) Após 5 iterações
 (c) Após 10 iterações (d) Após 15 iterações

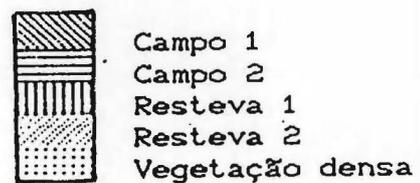
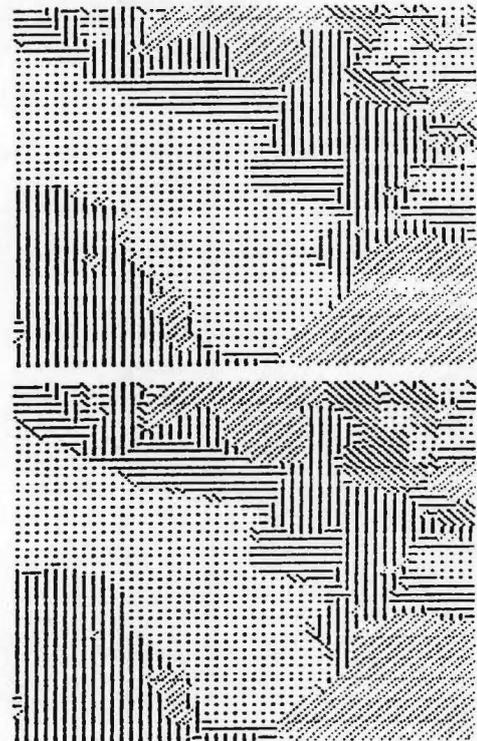
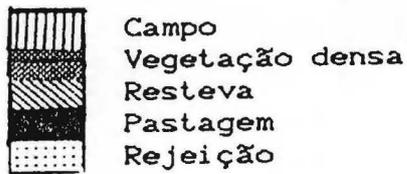
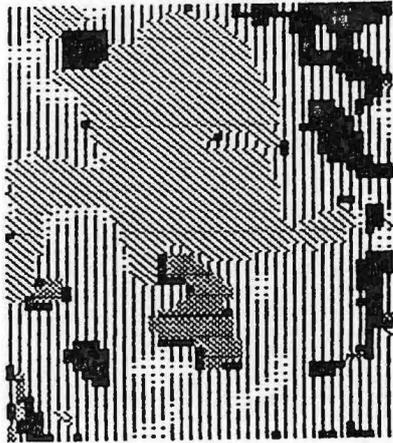


FIGURA A16: imagem temática Potiribú-1 após o processo combinado de filtragem espacial e de relaxação probabilística.

FIGURA A17: imagem temática Potiribú-2 após o processo combinado de filtragem espacial e de relaxação probabilística.
 (a) Após a filtragem.
 (b) Após a relax. Probabilística

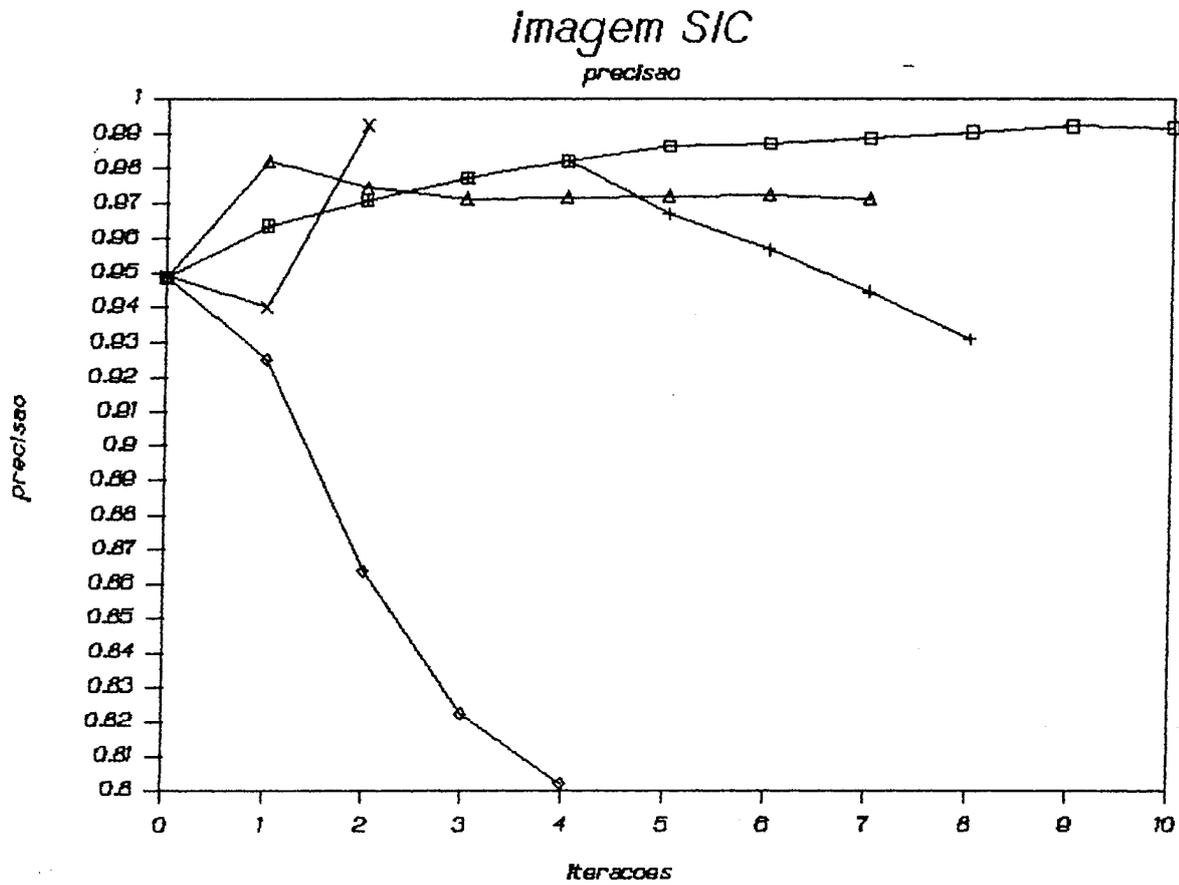


FIGURA A18: Evolução da precisão na imagem SIC

- Relaxação probabilística □
- Relaxação fuzzy ◇
- Relaxação fuzzy modificada com a média local △
- Processo combinado de Relaxação probabilística
e relaxação fuzzy +
- Processo combinado de filtragem espacial e
relaxação probabilística ×

imagem SIE

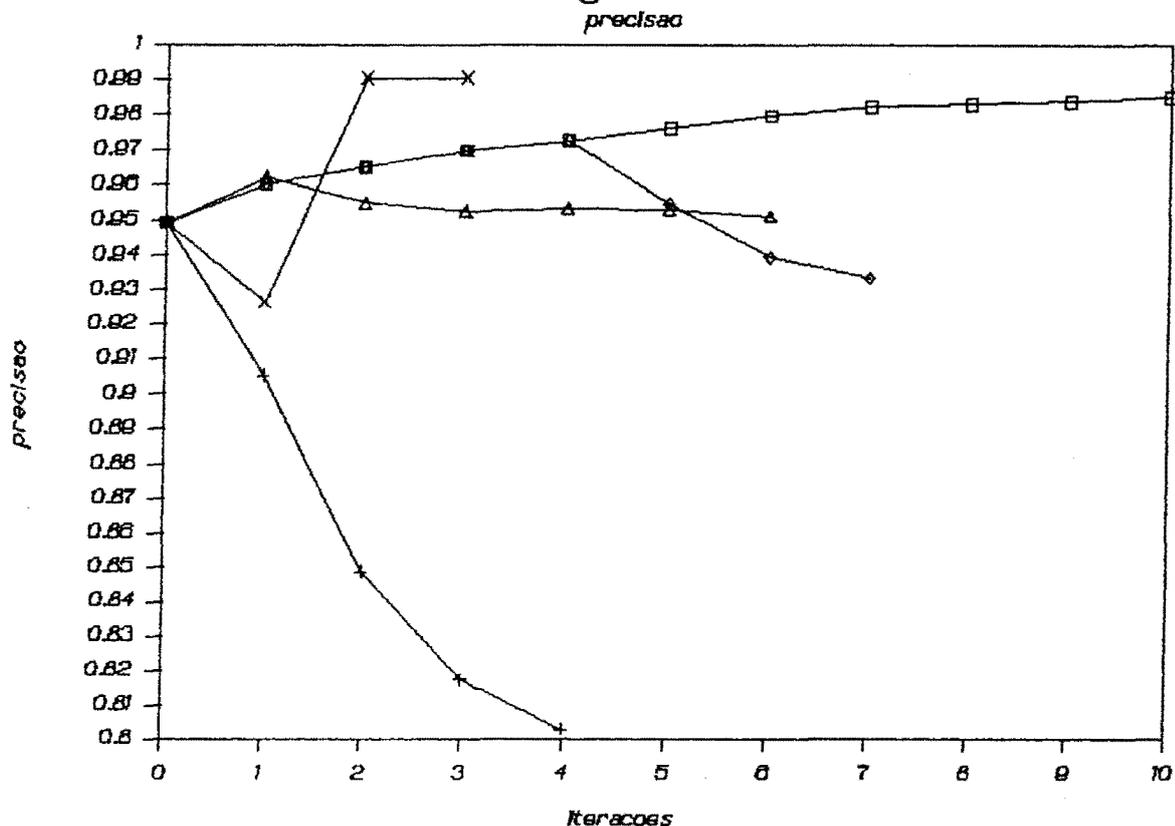


FIGURA A19: Evolução da precisão na imagem SIE

- Relaxação probabilística □
- Relaxação fuzzy +
- Relaxação fuzzy modificada com a média local Δ
- Processo combinado de Relaxação probabilística
e relaxação fuzzy ◇
- Processo combinado de filtragem espacial e
relaxação probabilística X

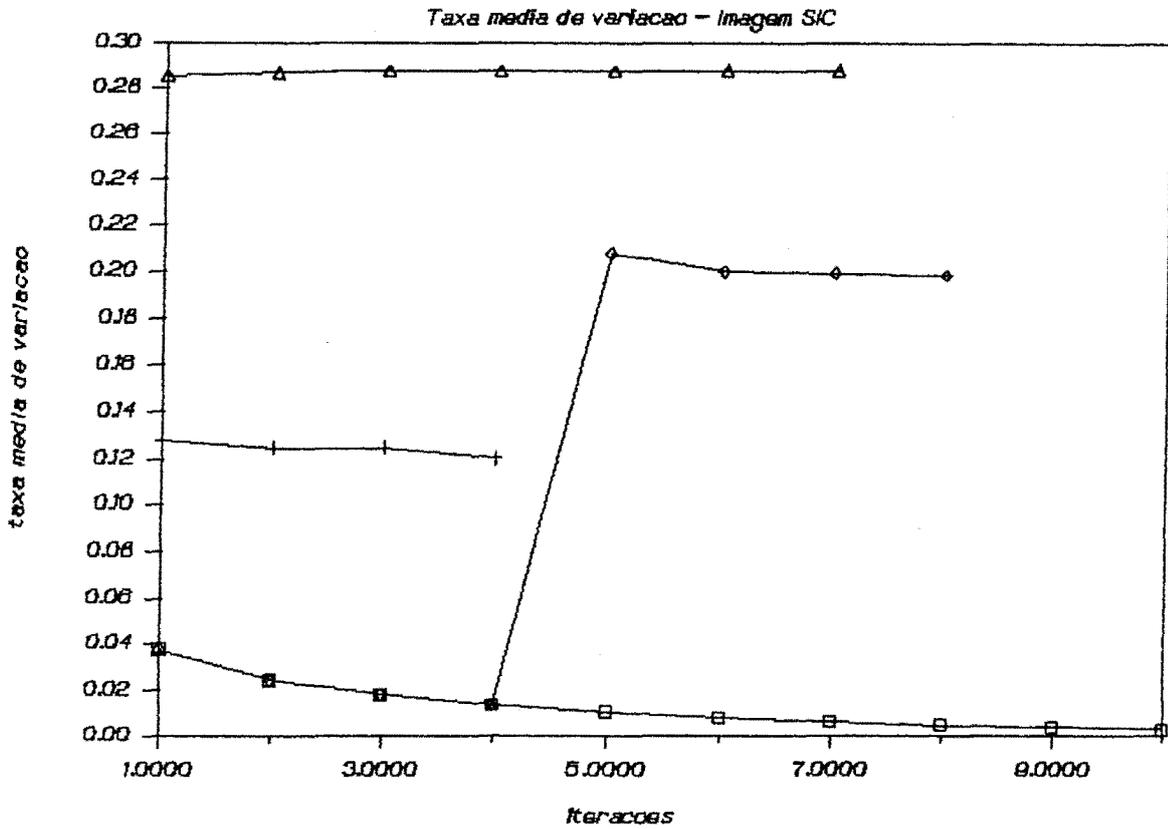


FIGURA A20: Evolução da taxa média de variação na imagem SIC

Relaxação probabilística □

Relaxação fuzzy Δ

Relaxação fuzzy modificada com a média local +

Processo combinado de Relaxação probabilística e relaxação fuzzy ◇

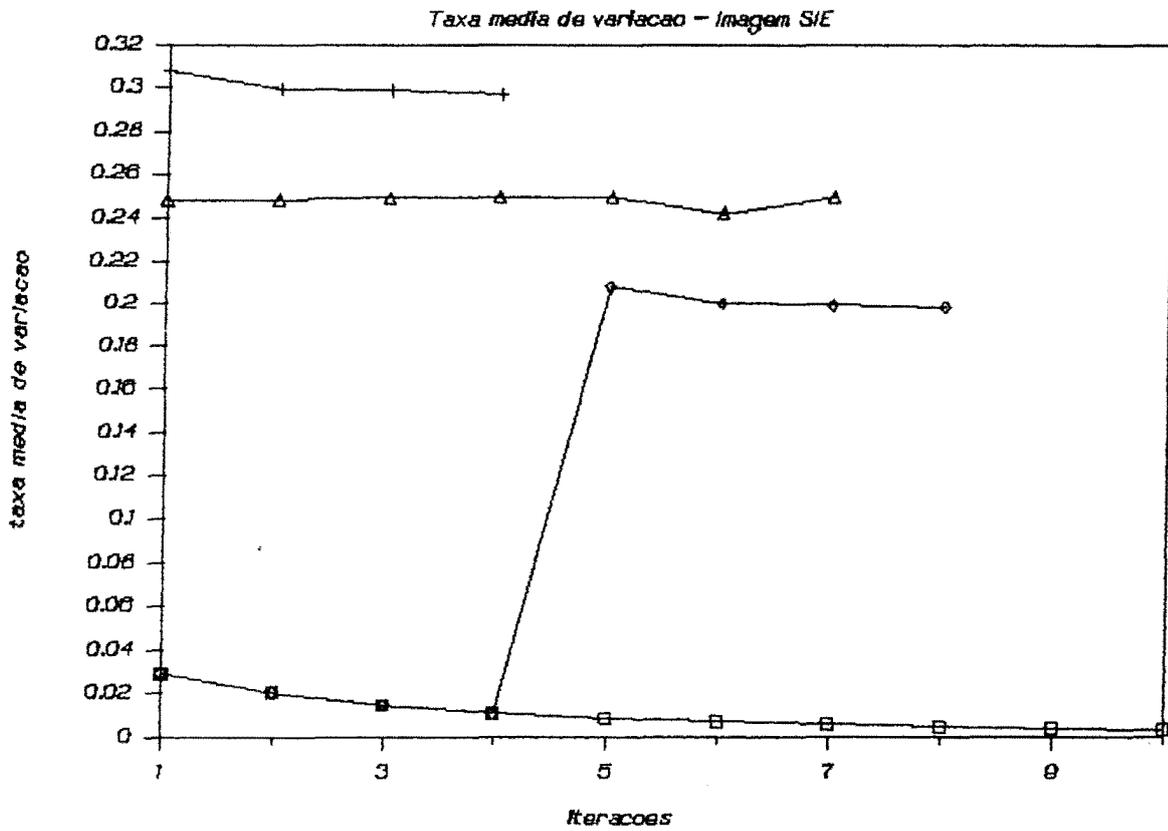


FIGURA A21: Evolução da taxa média de variação na imagem SIE

Relaxação probabilística □

Relaxação fuzzy +

Relaxação fuzzy modificada com a média local Δ

Processo combinado de Relaxação probabilística e relaxação fuzzy ◇

imagem SIC

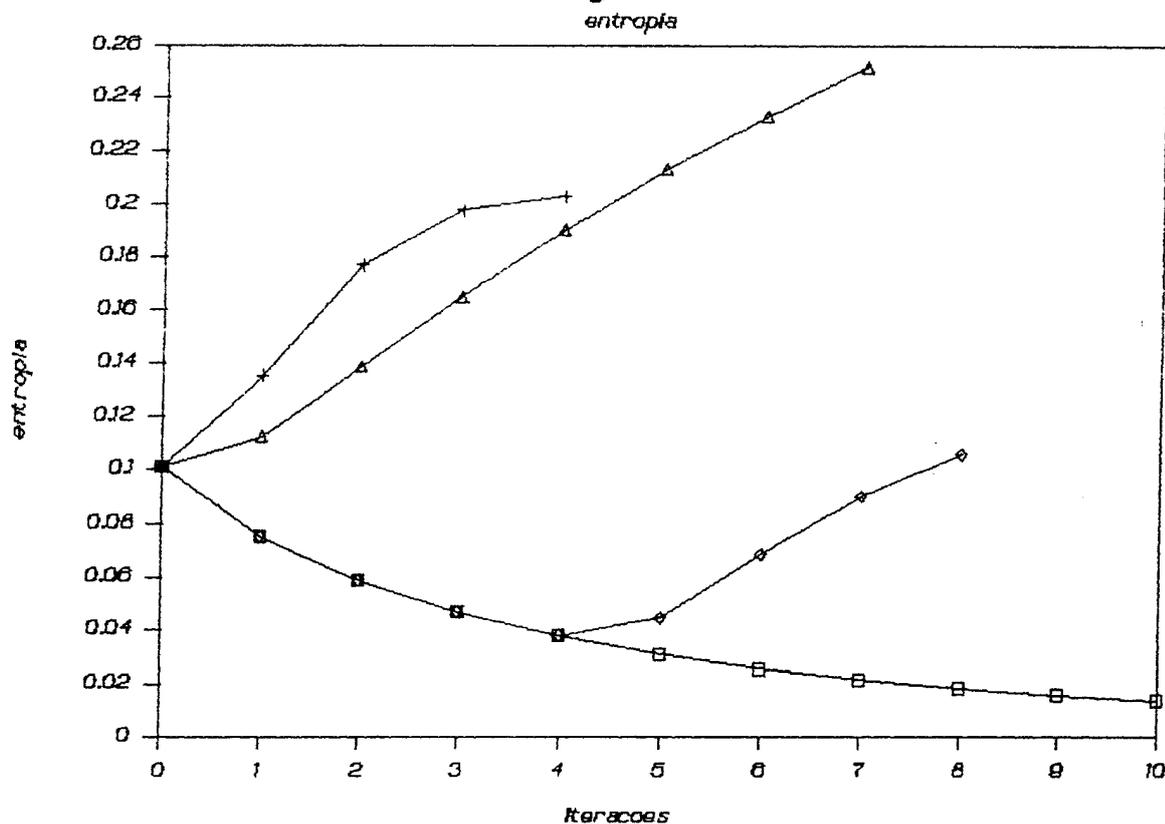


FIGURA A22: Evolução da entropia na imagem SIC

- Relaxação probabilística □
- Relaxação fuzzy +
- Relaxação fuzzy modificada com a média local Δ
- Processo combinado de Relaxação probabilística e relaxação fuzzy ◇

imagem SIE

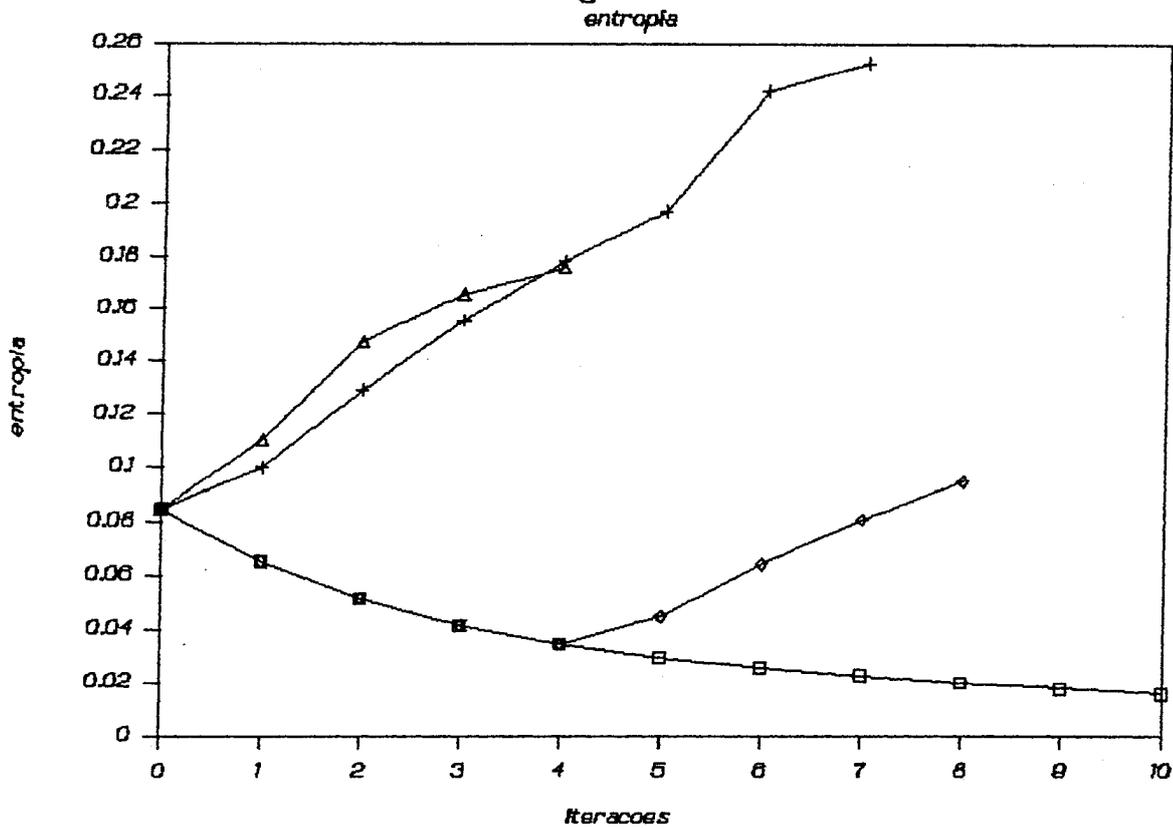


FIGURA A23: Evolução da entropia na imagem SIE

- Relaxação probabilística □
- Relaxação fuzzy △
- Relaxação fuzzy modificada com a média local +
- Processo combinado de Relaxação probabilística e relaxação fuzzy ◇