

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

**PROCESSAMENTO DE IMAGENS DIGITAIS: UMA ABORDAGEM
UTILIZANDO CONJUNTOS DIFUSOS**

**Tese submetida à Universidade Federal de Santa Catarina para a obtenção
do título de Doutor em Engenharia de Produção**

Édis Mafra Lapolli

Orientador: Prof. Ricardo Miranda Barcia, PhD

Florianópolis, janeiro de 1994

**PROCESSAMENTO DE IMAGENS DIGITAIS: UMA ABORDAGEM
UTILIZANDO CONJUNTOS DIFUSOS**

ÉDIS MAFRA LAPOLLI

Esta tese foi julgada adequada para a obtenção do título de DOUTOR EM ENGENHARIA DE PRODUÇÃO e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia de Produção.

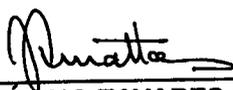


PROF. OSMAR POSSAMAI, Dr.
Coordenador do Curso

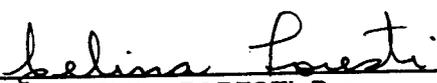
BANCA EXAMINADORA:



PROF. RICARDO MIRANDA BARCIA, Ph.D.
Orientador



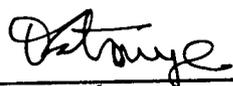
PROF. JUÉRCIO TAVARES DE MATTOS, Dr.
Examinador Externo



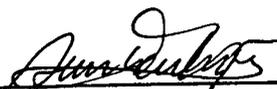
PROF. CELINA FORESTI, Dra.
Examinador Externo



PROF. EDGAR AUGUSTO LANZER, Ph.D.



PROF. PLÍNIO STANGE, Dr.



PROF. FERNANDO A. O. GAUTHIER, Dr.



PROF. HUMBERTO R. ROMAN, Ph.D.
Moderador

**Ao Flávio
À Juliana e à Mariana**

AGRADECIMENTOS

Ao professor e amigo Ricardo Miranda Barcia que, com sua experiência profissional e de vida, possibilitou o desenvolvimento deste trabalho, agradeço os ensinamentos transmitidos, tanto os acadêmicos quanto aqueles relacionados com sua filosofia de ação e de conduta.

Ao amigo Alceu Ribeiro Alves, um agradecimento especial pelos anos de convívio, pelas discussões relativas ao trabalho e, principalmente, pelos ensinamentos deixados com a sua partida.

Ao Fernando A. O. Gauthier, meu grande amigo, tanto nos bons momentos quanto naqueles de angústias e preocupações, agradeço e compartilho a alegria pela conclusão deste trabalho.

À professora e amiga Lia Caetano Bastos, pela inestimável colaboração, apoio e incentivo, sem os quais, em muitos momentos, eu teria sucumbido.

Ao professor Rogério Cid Bastos, amigo sempre presente, agradeço as sugestões e incansável colaboração.

À professora e amiga Ana Maria B. Franzoni, agradeço a constante amizade e o apoio incondicional dado em todo o transcorrer deste trabalho.

À minha amiga Soraia Marinon Zardo, agradeço o incentivo, a energia e a sua presença nos momentos certos.

Ao bolsista Rodrigo Becke Cabral, agradeço a dedicação, a vibração e o seu desempenho durante o desenvolvimento deste trabalho.

Ao bolsista Adriano Coser, agradeço a colaboração prestada.

Aos professores Juécio Tavares de Mattos e Celina Foresti, examinadores externos, agradeço os comentários e sugestões, tão valiosos ao trabalho desenvolvido.

Aos professores Plínio Stange, Edgar Augusto Lanzer e Fernando A. O. Gauthier, membros da banca examinadora, agradeço as contribuições recebidas durante o desenvolvimento deste trabalho.

Agradeço ao professor Humberto R. Roman, moderador, por sua brilhante atuação na condução dos trabalhos de apresentação e defesa da tese.

Ao Flávio, agradeço o incentivo, o reanimar a cada instante e a colaboração prestada em todo o decorrer do curso.

Às minhas filhas, Juliana e Mariana, agradeço pela compreensão da minha ausência, em momentos tão importantes de suas vidas.

À minha mãe, agradeço pelo amor, apoio e atenção dispensada à minha família.

À Zelita Chaves de Souza, secretária do Programa de Pós-Graduação em Engenharia de Produção, agradeço pelo apoio durante todo o transcorrer do curso.

Agradeço ao Dalmocir Mafra pela contribuição nos trabalhos fotográficos utilizados na defesa e apresentação da tese.

Agradeço, ainda, ao Laboratório Associado de Sensoriamento Remoto de Santa Catarina pelo apoio logístico.

RESUMO

Nas últimas décadas, as técnicas de Sensoriamento Remoto evoluíram consideravelmente. Técnicas especiais são aplicadas para processar e interpretar imagens obtidas por sensoriamento remoto, com o propósito de produzir mapas convencionais, mapas temáticos etc. Entre essas técnicas, a classificação de imagens digitais é considerada uma das principais.

A classificação, através de técnicas convencionais, não diferencia noções de intensidade da pertinência de um pixel em uma dada classe, mas somente como pertencente ou não a uma classe. Informações geográficas, porém, não são precisas. Mais de uma classe pode estar presente numa determinada área do terreno.

Numa representação através de conjuntos difusos, classes de uso/cobertura do solo podem ser definidas como conjuntos difusos cujos elementos são os pixels. A introdução da teoria dos conjuntos difusos permite, no processo de classificação e análise de imagens digitais, identificar pixels que são bem representativos de cada classe e pixels mistos ou intermediários.

Este trabalho apresenta uma abordagem baseada na teoria dos conjuntos difusos para o processamento de imagens digitais obtidas por sensoriamento remoto. Um classificador e técnicas de tratamento e manipulação das informações obtidas são propostas.

A abordagem proposta foi implementada num sistema computacional que incorpora, também, funções normalmente encontradas em outros sistemas existentes.

Aplicações práticas são desenvolvidas, com a finalidade de mostrar algumas das muitas informações que podem ser obtidas e manuseadas.

ABSTRACT

In the last decades Remote Sensing techniques have considerably evolved. Aiming to develop conventional and thematic maps especial techniques have been used for processing and interpreting images obtained through remote sensing.

Classification through conventional techniques does not differentiate intensity or pixel membership to a certain class. Geographical information is not crisp though. More than one class may exist on a terrain.

When using a Fuzzy Sets Theory representation, land cover classes may be defined as fuzzy sets having pixels as elements. Fuzzy Sets Theory allows to identify pixels well representatives of classes and mixed pixels.

This work presents an approach based on Fuzzy Sets Theory for digital image processing. A classifier and techniques for treating and manipulating information are propose. A computational system on which the proposed approach was implemented is presented.

Real world applications are developed aiming to demonstrate the proposed approach potentialities.

SUMÁRIO

		pág.
1.	INTRODUÇÃO	1
1.1	Origem do Trabalho	1
1.2	Objetivos do Trabalho	2
1.3	Justificativa e Importância do Trabalho	3
1.4	Estrutura do Trabalho	4
2.	RECONHECIMENTO DE PADRÕES	6
2.1	Introdução	6
2.2	Definição	6
2.3	Problemas Existentes no Reconhecimento de Padrões	7
2.4	Métodos Utilizados no Reconhecimento de Padrões	10
2.5	Sistemas de Reconhecimento de Padrões Sintáticos	12
2.6	Reconhecimento de Padrões Através de Redes Neurais	13
2.7	Conclusão	15
3.	CONJUNTOS DIFUSOS	17
3.1	Introdução	17
3.2	Definição	18
3.3	Definições Básicas e Operações da Teoria dos Conjuntos Difusos	19
3.4	Funções de Pertinência	21
3.5	Estimação de Funções de Pertinência	22
3.5.1	Método Baseado no Consenso de Especialistas	22
3.5.2	Método Baseado em Histograma	23
3.6	Medidas de Possibilidade	23
3.6.1	Possibilidade e Conjuntos Difusos	24

		pág.
3.6.2	Possibilidade de um Evento Não Difuso	24
3.6.3	Princípio de Consistência	25
3.7	Algoritmos Difusos	25
3.8	Lógica Difusa	28
3.9	Conclusão	29
4.	PROCESSAMENTO DIGITAL DE IMAGENS	30
4.1	Introdução	30
4.2	Definição	30
4.3	Técnicas de Pré-processamento	31
4.3.1	Eliminação de Ruído	31
4.3.2	Correção Atmosférica	33
4.3.3	Registro de Imagens	34
4.3.4	Aplicações das Técnicas de Pré-processamento	37
4.4	Técnicas de Realce	41
4.4.1	Manipulação de Contraste	42
4.4.2	Filtragem Espacial	43
4.4.3	Transformação IHS	44
4.4.4	Transformação por Componentes Principais	46
4.4.5	Divisão entre Canais	48
4.4.6	Aplicações de Técnicas de Realce	49
4.5	Técnicas de Classificação de Imagens Digitais	52
4.5.1	Métodos de Classificação Supervisionados	54
4.5.2	Métodos de Classificação Não Supervisionados	59
4.5.3	Incorporação de Dados Auxiliares nos Métodos de Classificação	60
4.5.4	Medida da Precisão da Classificação	62
4.5.5	Abordagens Atuais e Perspectivas de Novos Desenvolvimentos	64
4.5.6	Aplicações de Técnicas de Classificação	66
4.6	Conclusão	72

	pág.	
5.	CONJUNTOS DIFUSOS EM PROCESSAMENTO DE IMAGENS DIGITAIS	74
5.1	Introdução	74
5.2	Partição Difusa do Espaço Espectral	75
5.3	Algoritmo para Classificação Difusa	76
5.3.1	Função de Pertinência Utilizada no Algoritmo para Classificação Difusa	77
5.3.2	Cálculo dos Parâmetros da Distribuição Multivariada	78
5.3.3	Cálculo das Pertinências dos Pixels da Amostra	80
5.3.4	Algoritmo de Classificação Difusa	80
5.4	Manipulação de Informações Obtidas pelo Método de Classificação	83
5.4.1	Imagens de Pertinência	83
5.4.2	Imagem Classificada de Nível Alfa	84
5.4.3	Determinação do Contexto Difuso de um Pixel	85
5.4.4	Similaridade Difusa	86
5.4.5	Áreas a Diferentes Níveis de Pertinência	87
5.5	Conclusão	88
6.	EDIMA: SISTEMA COMPUTACIONAL PARA ANÁLISE E TRATAMENTO DE IMAGENS DIGITAIS	90
6.1	Introdução	90
6.2	Modelo Computacional para Processamento de Imagens	91
6.2.1	Desenvolvimento através de Orientação a Objetos	91
6.2.2	Características Básicas do Modelo Computacional	92
6.2.3	Ambiente de Desenvolvimento do Modelo Computacional	92
6.2.4	Objetos Básicos Definidos no Modelo Computacional	93
6.2.5	Sistema EDIMA: Uma Visão Global	95
6.3	Algoritmos e Funções Implementados	102
6.3.1	Funções Básicas	102
6.3.2	Funções de Pré-processamento	107
6.3.3	Funções de Processamento	114

	pág.
6.3.4	Funções de Posprocessamento 122
6.4	Considerações Finais 128
7.	APLICAÇÕES DA ABORDAGEM PROPOSTA 129
7.1	Introdução 129
7.2	Identificação de Metaclasses Através de Informações Difusas 129
7.2.1	Procedimento Adotado 131
7.2.2	Análise dos Resultados 140
7.3	Análise de Crescimento 141
7.3.1	Procedimento Adotado 141
7.3.2	Análise dos Resultados 152
7.4	Detecção de Mudança 152
7.4.1	Procedimento Adotado 153
7.4.2	Análise dos Resultados 154
7.5	Desempenho do Classificador Difuso 166
7.6	Conclusão 174
8.	CONCLUSÕES E RECOMENDAÇÕES 175
8.1	Conclusões 175
8.2	Recomendações 178
	BIBLIOGRAFIA 180

LISTA DE FIGURAS

	pág.	
FIGURA 2.1	Descrição Estrutural Hierárquica da Cena A	11
FIGURA 2.2	Diagrama de um Sistema de Reconhecimento de Padrões Sintáticos	12
FIGURA 3.1	Grau de Pertinência dos Números Reais Próximos a 10	19
FIGURA 4.1	Conjunto de Bandas de uma Imagem Obtida por Sensoriamento Remoto	53
FIGURA 5.1	Partição do Espaço Espectral	75
FIGURA 5.2.	Partição Difusa do Espaço Espectral	76
FIGURA 5.3	Exemplo de Duas Áreas a Diferentes Níveis Alfa	87
FIGURA 6.1	Objetos Básicos Definidos no Sistema EDIMA	94
FIGURA 6.2	Objetos Visíveis ao Usuário	94
FIGURA 6.3	Ambiente do Projeto	97
FIGURA 6.4	Exemplos de Janelas de Um Projeto	97
FIGURA 6.5	Janela do Tipo Banda	98
FIGURA 6.6	Composição Colorida	98
FIGURA 6.7	Obtenção de Amostras	99
FIGURA 6.8	Localização das Amostras	99
FIGURA 6.9	Imagem Classificada	101
FIGURA 6.10	Imagem de Pertinência	101
FIGURA 6.11	Funções de Arquivo	103
FIGURA 6.12	Funções de Janelas	103
FIGURA 6.13	Tipos de Arquivo da Função Novo	103
FIGURA 6.16	Dados para a Imagem Sintética	104
FIGURA 6.15	Informações para Geração de uma Classe	104
FIGURA 6.16	Janela de Propriedades	106
FIGURA 6.17	Funções de Gerenciamento de Projeto	106
FIGURA 6.18	Função de Manipulação de Contraste	108
FIGURA 6.19	Transformação Linear	108
FIGURA 6.20	Transformação Linear por Partes	109
FIGURA 6.21	Tamanhos de Máscara Disponíveis	109
FIGURA 6.22	Exemplo de Máscara 3x3	110

	pág.
FIGURA 6.23 Banda Filtrada	110
FIGURA 6.24 Janela de Registro Contendo Duas Bandas e Janela com Dados dos Pontos	112
FIGURA 6.25 Delimitação de Área	112
FIGURA 6.26 Histograma de uma Banda	113
FIGURA 6.27 Recorte de Área	113
FIGURA 6.28 Operações Lógicas	115
FIGURA 6.29 Interface da Transformação RGB/IHS	115
FIGURA 6.30 Arquivos de Amostras	117
FIGURA 6.31 Escolha das Bandas para o Processo de Classificação	117
FIGURA 6.32 Imagem Classificada - Máxima Verossimilhança	117
FIGURA 6.33 Interface de Gerenciamento do Classificador Difuso	119
FIGURA 6.34 Imagens de Pertinência	119
FIGURA 6.35 Imagem Classificada - Classificador Difuso	120
FIGURA 6.36 Áreas de uma Classe aos Diferentes Níveis de Pertinência	120
FIGURA 6.37 Similaridade a um Padrão	121
FIGURA 6.38 Padrão de Uma Metaclassa	121
FIGURA 6.39 Limiar e Peso Solicitado ao Usuário	123
FIGURA 6.40 Imagem Classificada com Uniformização de Temas	123
FIGURA 6.41 Desempenho das Diferentes Classes	124
FIGURA 6.42 Desempenho das diferentes Áreas de Treinamento de uma Classe	124
FIGURA 6.43 Coeficiente Kappa para uma Classificação	125
FIGURA 6.44 Comparação entre Duas Classificações	125
FIGURA 6.45 Classe Extraída de uma Classificada	127
FIGURA 6.46 Resultado da Comparação entre Duas Bandas	127
FIGURA 7.1 Imagem Original - bandas 1,2 e 3	133
FIGURA 7.2 Imagem Resultante - banda R,G e B	134
FIGURA 7.3 Identificação de Metaclassa 1 - Residencial Antiga	137
FIGURA 7.4 Identificação de Metaclassa 2 - Residencial Nova	138

	pág.	
FIGURA 7.5	Cruzamento das Metaclasses 1 e 2	139
FIGURA 7.6	Composição Colorida da Imagem de 03/05/84 - bandas 4,5 e 3	142
FIGURA 7.7	Composição Colorida da Imagem de 06/11/88 - bandas 4,5 e 3	143
FIGURA 7.8	Área Urbana Extraída da Imagem Classificada - 1984	145
FIGURA 7.9	Área Urbana Extraída da Imagem Classificada - 1988	146
FIGURA 7.10	Cruzamento entre Áreas Urbanas Extraídas das Imagens Classificadas - 1984/1988	147
FIGURA 7.11	Área Urbana em 1984 e Não Urbana em 1988	148
FIGURA 7.12	Área Não Urbana em 1984 e Urbana em 1988	149
FIGURA 7.13	Área Não Urbana em 1984 e Não Urbana em 1988	150
FIGURA 7.14	Área Urbana em 1984 e Urbana em 1988	151
FIGURA 7.15	Mistura entre as Classes Área de Mineração e Área Urbana - 1984	156
FIGURA 7.16	Mistura entre as Classes Gramínea e Área Urbana - 1984	157
FIGURA 7.17	Mistura entre as Classes Área de Mineração e Área Urbana - 1988	158
FIGURA 7.18	Mistura entre as Classes Gramínea e Área Urbana - 1988	159
FIGURA 7.19	Área de Mudança - Área de Mineração/ Área Urbana em 1984 para Área Urbana em 1988	160
FIGURA 7.20	Área de Mudança - Gramínea / Área Urbana em 1984 para Área Urbana em 1988	161
FIGURA 7.21	Área de Não Mudança - Gramínea / Área Urbana em 1984 e 1988	162
FIGURA 7.22	Área de Mudança - Vegetação em 1984 para Área Urbana em 1988	163
FIGURA 7.23	Área de Mudança - Área de Mineração em 1984 para Área Urbana em 1988	164
FIGURA 7.24	Área de Mudança - Gramínea em 1984 para Área Urbana em 1988	165
FIGURA 7.25	Imagem Sintética - Composição Colorida	171

LISTA DE TABELAS

		pág.
TABELA 7.1	Padrão para Metaclassse 1: Residencial Antiga	135
TABELA 7.2	Padrão para Metaclassse 2: Residencial Nova	135
TABELA 7.3	Áreas das Classes Resultantes do Cruzamento	144
TABELA 7.4	Síntese das Mudanças Ocorridas na Classe Área Urbana entre 1984 e 1988 (Km ²)	154
TABELA 7.5	Áreas das Classes - Classificador de Máxima Verossimilhança	167
TABELA 7.6	Desempenho do Classificador de Máxima Verossimilhança	167
TABELA 7.7	Matriz-Confusão - Classificador de Máxima Verossimilhança	167
TABELA 7.8	Áreas das Classes - Classificador Difuso	168
TABELA 7.9	Desempenho do Classificador Difuso	168
TABELA 7.10	Matriz-Confusão - Classificador Difuso	168
TABELA 7.11	Coefficientes Kappa para os Classificadores Utilizados	169
TABELA 7.12	Estatísticas t para Diferenças	169
TABELA 7.13	Desempenho dos Classificadores - Amostra 1	172
TABELA 7.14	Desempenho dos Classificadores - Amostra 2	173

1. INTRODUÇÃO

1.1 Origem do Trabalho

Nas últimas décadas as técnicas de Sensoriamento Remoto evoluíram consideravelmente. Técnicas especiais são aplicadas para processar e interpretar imagens obtidas por sensoriamento remoto com o propósito de produzir mapas convencionais, mapas temáticos etc., nos campos de agricultura, arqueologia, florestas, geografia, geologia, engenharia e outros. Entre essas técnicas, a classificação de imagens digitais é considerada uma das principais.

A análise dos dados obtidos por sensoriamento remoto, no entanto, está sujeita a erros, pois, as informações derivadas são, essencialmente imprecisas. Essa imprecisão é resultante tanto da natureza dos dados quanto do resultado do seu processamento.

Atualmente, para a classificação de imagens digitais são usados métodos convencionais que apresentam uma limitação no momento em que uma regra de decisão é aplicada. Isto é, pixels são atribuídos a uma determinada classe e as medidas que foram calculadas e que serviram de base para essa decisão são abandonadas. Evidentemente, essas medidas apresentam um valor mais diferenciado para pixels que são representativos de cada classe e um valor menos diferenciado para os pixels mistos ou intermediários. Como o objetivo é a atribuição de cada pixel a uma classe, o resultado é o mesmo, seja o pixel representativo ou não. Dessa forma, a informação a respeito da representatividade do pixel dentro de uma classe é perdida.

A limitação derivada dos processos convencionais de classificação está diretamente relacionada com o princípio do meio excluído da lógica clássica. Através desse princípio, as relações de pertinência a uma classe ou conjunto dentro da teoria clássica de conjuntos são dicotômicas. Entretanto, informações geográficas são de natureza imprecisa.

A teoria dos conjuntos difusos permite, de uma forma adequada, modelar situações em que ocorram imprecisões. De acordo com essa teoria, um

conjunto não tem limites nitidamente definidos. Um elemento pode pertencer parcialmente a um conjunto ou pertencer a mais de um conjunto ao mesmo tempo.

Com a idéia básica de fornecer subsídios ao tomador de decisão que utiliza as informações oriundas dos processos de classificação de imagens digitais, e propor uma melhoria nos classificadores convencionais, de forma a aumentar a sua eficiência, desenvolveu-se este trabalho.

1.2 Objetivos do Trabalho

O objetivo geral deste trabalho é o de melhorar o processo de classificação de imagens digitais através da obtenção de novas informações que não são passíveis de serem extraídas utilizando-se os classificadores existentes. Essa melhoria consiste na identificação e manipulação de pixels mistos. Consegue-se esses novos resultados através do uso da teoria de conjuntos difusos.

Como objetivos específicos têm-se:

- desenvolver um classificador difuso para imagens digitais obtidas por sensoriamento remoto;
- manipular as informações difusas oriundas do classificador desenvolvido;
- desenvolver um sistema computacional para processamento de imagens digitais o qual englobe o tratamento baseado em lógica difusa.

1.3 Justificativa e Importância do Trabalho

Dada a disponibilidade de imagens de sensoriamento remoto na forma digital (obtidas tanto a partir de satélites quanto de aeronaves) e a acessibilidade a sistemas computacionais, uma questão fundamental é o aprimoramento de técnicas e de metodologias utilizadas para sua análise.

As técnicas convencionais utilizadas na tarefa de processamento de imagens obtidas por sensoriamento remoto são, em sua maioria, derivadas da análise estatística.

O tratamento de imagens digitais através de técnicas estatísticas convencionais não diferencia noções de intensidade da presença de um pixel em uma determinada classe. Ao contrário, o pixel é atribuído ou não a uma certa classe. Em termos de resultado final, tal abordagem pode acarretar distorções. Esse problema é resolvido pela aplicação dos conceitos derivados da teoria de conjuntos difusos.

A introdução dessa teoria, no processo de classificação de imagens digitais, faz com que não haja perda de informação, permitindo identificar pixels que são bem representativos de cada classe e pixels mistos ou intermediários. Numa representação difusa, classes de uso/cobertura do solo podem ser definidas como conjuntos difusos cujos elementos são os pixels.

Entre os trabalhos que utilizam conceitos de conjuntos difusos para processamento de informação geográfica destacam-se o de CANNON et al que desenvolveu um algoritmo de agrupamento das c-médias (BEZDEK 1987) para segmentar uma imagem. WANG (1989) direcionou o seu trabalho para a integração de sistemas especialistas de sensoriamento remoto e sistemas de informações geográficas, estudando detalhadamente problemas relacionados com formatos dos dados, precisão dos dados e sistemas de comunicação entre os sistemas especialistas de sensoriamento remoto e os sistemas de informações geográficas. Entretanto, essas abordagens não exploram o potencial completo de conjuntos difusos no processamento de imagens digitais, dado que limitam-se a aspectos específicos do problema.

A importância do presente trabalho consiste no desenvolvimento de uma nova forma de análise de imagens obtidas por sensoriamento remoto. Além do classificador, propõe-se uma forma de representar os resultados obtidos através de imagens de pertinências. A representação do resultado como uma partição difusa do espaço espectral permite ainda a aplicação de técnicas oriundas da teoria dos conjuntos difusos. Essas técnicas englobam processos de tomada de decisão em ambientes nos quais apesar dos dados serem imprecisos e vagos, novas informações podem ser inferidas.

1.4 Estrutura do Trabalho

Este trabalho encontra-se estruturado em oito capítulos.

Neste capítulo, a origem, os objetivos e a justificativa da pesquisa são descritos. Sua finalidade é introduzir o tema da pesquisa e a estrutura do trabalho.

O segundo capítulo apresenta uma abordagem teórica sobre reconhecimento de padrões.

No terceiro capítulo, conceitos fundamentais da teoria dos conjuntos difusos são apresentados, conceitos esses necessários para modelagem do problema em questão.

Dedica-se o quarto capítulo a uma abordagem teórica sobre processamento de imagens digitais.

O processamento de imagens digitais obtidas por sensoriamento remoto, é abordado no quinto capítulo com base em conceitos e técnicas oriundos da teoria de conjuntos difusos.

Um sistema computacional desenvolvido para processamento e análise de imagens digitais, é apresentado a seguir. O sistema EDIMA engloba técnicas tradicionais e a abordagem proposta no capítulo anterior.

No sétimo capítulo apresentam-se aplicações utilizando a abordagem proposta, onde é verificada sua operacionalidade e são avaliados os resultados obtidos.

O capítulo seguinte, o oitavo, apresenta as conclusões e recomendações para futuras pesquisas.

2. RECONHECIMENTO DE PADRÕES

2.1 Introdução

O reconhecimento automático de padrões tem sido objeto de investigação de pesquisadores de diversos campos: computação, controle automático, teoria da informação, física aplicada, estatística, biologia, psicologia, medicina e linguística, etc. Cada um desses grupos dá ênfase a determinados aspectos do problema.

De forma geral, a área de reconhecimento de padrões abrange leitura de caracteres alfanuméricos; análise de imagens aeroespaciais, biomédicas, reconhecimento de voz; análise de sinais de sonar; eletrocardiograma; eletroencefalograma; etc.

2.2 Definição

Para BEZDEK (1987), o reconhecimento de padrões é a busca de estruturas nos dados. Os dados trazem informações sobre os processos que os geraram e a estrutura é a forma como a informação pode ser organizada, de modo que as relações entre as variáveis no processo possam ser identificadas.

Em um sistema de reconhecimento automático de padrões, os padrões a serem reconhecidos e classificados devem possuir um conjunto de características mensuráveis. Quando essas medidas são similares em um grupo de padrões, esses são considerados da mesma classe.

Com base no exposto acima, pode-se deduzir que o objetivo de um sistema de reconhecimento de padrões é determinar, levando em consideração a informação observada, a classe de padrões que é responsável pela geração de um conjunto de medidas similares dos dados observados. O reconhecimento

correto dependerá do montante de informação discriminatória contida nas medidas e da efetiva utilização da informação discriminatória disponível.

2.3 Problemas Existentes no Reconhecimento de Padrões

O primeiro problema nos sistemas de reconhecimento de padrões relaciona-se com os dados de entrada que podem ser medidos a partir dos elementos de uma classe de padrões. Trata-se de um problema de percepção. Cada quantidade a ser medida descreve uma característica do padrão. Padrões bidimensionais, como caracteres, letras, imagens, podem ser medidos por dispositivos que expõem o padrão ponto por ponto. Tais instrumentos de medida apresentam o padrão num sistema de coordenadas discretas bidimensionais, como uma matriz com n elementos. Os padrões a serem reconhecidos são freqüentemente representados por vetores coluna de dimensão n ou por espaços n -dimensionais. Cada dimensão expressa uma propriedade do padrão. Os componentes do vetor têm valores numéricos correspondendo ao montante de cada propriedade que o elemento apresenta. O vetor de medidas de um padrão pode também ser formado pelos valores numéricos de um conjunto de descritores que foram gerados pelos resultados de n testes quantitativos realizados no padrão de entrada. O uso da representação vetorial dos padrões fornece uma interpretação geométrica da distribuição dos vários padrões no espaço de medidas. O conjunto de padrões que pertencem à mesma classe corresponde a um conjunto de pontos localizados dentro de uma região do espaço de medidas. O conjunto de pontos que representam diferentes padrões que pertencem à mesma classe deve agrupar-se no espaço n -dimensional, de forma que a distância entre pontos padrões da mesma classe seja pequena. A distância entre pontos padrões da mesma classe é chamada distância intra-conjuntos, e a distância entre pontos padrões de classes diferentes é chamada distância inter-conjuntos (SWAIN e DAVIS, 1978).

O segundo problema em reconhecimento de padrões relaciona-se com a seleção de características ou atributos dos dados de entrada e a redução da dimensionalidade dos vetores de medidas (MASCARENHAS e VELASCO, 1989). Isso é normalmente referido como problema de seleção de características e preprocessamento. As características de uma classe padrão são atributos que

a definem, comuns a todos os padrões daquela classe. Elas são denominadas características intra-conjuntos. As características que representam as diferenças entre classes padrões são denominadas características inter-conjuntos. Os elementos das características intra-conjuntos que são comuns a todas classes de padrões em consideração não fornecem informação discriminatória, e podem ser ignorados. A seleção de características sempre foi considerada um problema importante em sistemas de reconhecimento de padrões. Quando o conjunto total de características discriminatórias para cada classe de padrões pode ser determinado a partir dos dados medidos, não há problemas no reconhecimento e classificação dos padrões. Entretanto, na maioria dos problemas de reconhecimento de padrões que ocorrem na prática, a determinação de um conjunto completo de características discriminatórias é bastante difícil, se não impossível. Muitas vezes, tem-se condições de determinar algumas características discriminatórias dos dados observados. Essas características podem então ser usadas para simplificar o processo de reconhecimento automático. Nesse caso, pode-se reduzir a dimensionalidade dos vetores de medidas, usando uma transformação que acarrete uma perda mínima de informação.

O terceiro problema está relacionado com a determinação dos procedimentos de decisão que são necessários nos processos de identificação e classificação. Depois que os dados observados dos padrões a serem reconhecidos tenham sido expressos na forma de pontos padrão ou vetores de medidas no espaço padrão, deseja-se que uma máquina decida a que classe de padrões os dados observados pertencem. Supondo-se que a máquina tenha sido projetada para reconhecer M diferentes classes de padrões, então, o espaço padrão pode ser considerado como consistindo de M regiões disjuntas. O problema do reconhecimento pode então ser expresso como o problema de gerar limites que separam as M classes de padrões, com base nos vetores de medidas observados. Esses limites de decisão são definidos por funções de decisão ou funções discriminantes, que são funções escalares do padrão x . Normalmente, essas funções são definidas de forma que, se para o padrão x , a função discriminante apresenta o maior valor na classe i , então o padrão x pertence à classe i . Quando os vetores padrões de medidas das diferentes classes formam regiões sobrepostas, não podem ser gerados limites para categorizar as classes padrões. Nesse caso, a máquina de reconhecimento de padrões pode ser treinada para aprender as funções de reconhecimento que atribuem o padrão de entrada a uma certa classe.

Existem diversas formas de gerar as funções discriminantes (KENDALL e STUART, 1968). Quando se tem um conhecimento a priori sobre os padrões a serem reconhecidos, as funções discriminantes podem ser determinadas com precisão. Quando se tem somente conhecimento qualitativo sobre os padrões, podem ser feitas suposições razoáveis sobre a forma das funções discriminantes. Nesse caso, os limites de decisão podem estar deslocados em relação a posição real, e a máquina deve ser projetada para obter um desempenho satisfatório através de uma seqüência de ajustamentos. O caso mais geral, entretanto, é aquele em que existe pouco ou nenhum conhecimento a priori sobre os padrões a serem reconhecidos. As máquinas para reconhecer esses padrões são melhor projetadas usando um procedimento de treinamento. Inicialmente, escolhe-se uma função discriminante pouco representativa. Através de uma seqüência de treinamento, a função inicialmente escolhida é melhorada, até se aproximar de uma forma ótima ou satisfatória.

A classificação dos padrões por limites de decisão pode ser feita usando diferentes tipos de funções. As mais comuns são as que usam as propriedades da distribuição dos padrões, onde se incluem a função distância, a função de verossimilhança e a função entropia.

A resolução de problemas de seleção de características, preprocessamento, decisão ótima e classificação envolve uma série de parâmetros a serem estimados e otimizados (FU, 1982). Esse fato dá origem ao problema de estimação de parâmetros. Além disso, considera-se que tanto o processo de seleção de características como o processo de decisão podem ser melhorados pelo uso da informação contextual existente nos padrões. Informação contextual pode ser medida, por exemplo, através de probabilidades condicionais e variações de vizinhança. Em algumas aplicações, a informação contextual é indispensável para realizar um reconhecimento preciso. Um outro problema que deve ser levado em consideração é o problema de adaptação, o qual ocorre quando se quer projetar um sistema de reconhecimento de padrões que seja resistente a distorções, flexível, no caso de haver grandes desvios nos padrões, e capaz de auto ajustar-se.

O objetivo de um sistema de reconhecimento de padrões é determinar, com base na informação observada, a classe de padrões que é responsável pela geração de um conjunto de medidas similares dos dados observados. O reconhecimento correto irá depender da quantidade de

informação discriminatória contida nas medidas e da sua efetiva utilização. Se todas as características possíveis podem ser medidas e não existe limitação de tempo para processar a informação, uma técnica de "força bruta" pode ser aplicada, a fim de obter um reconhecimento de padrões bastante adequado. Entretanto, restrições de tempo, espaço e custo obrigam ao uso de métodos mais refinados.

2.4 Métodos Utilizados no Reconhecimento de Padrões

As técnicas matemáticas utilizadas para solucionar problemas de reconhecimento de padrões podem ser agrupadas em dois métodos gerais: o método de decisão teórica ou discriminante, e o método sintático, linguístico ou estrutural (FU, 1982).

No primeiro método, um conjunto de medidas características são extraídas dos padrões. O reconhecimento de cada padrão, ou seja, a sua designação para uma determinada classe, é normalmente feito pelo particionamento do espaço característico. A ferramenta básica é a teoria da decisão estatística, embora, às vezes, sejam empregadas técnicas essencialmente determinísticas.

Um exemplo de aplicação do método de decisão teórica ocorre na classificação de uma imagem digital de satélite, em que cada pixel da imagem deve ser atribuído a uma classe de uso do solo (RICHARDS, 1986). Uma característica que pode ser considerada, nesse caso, é o valor do nível de cinza de cada pixel. Defini-se, então, uma função discriminante, baseada no valor do nível de cinza, que atribui os pixels da imagem as diferentes classes. A identificação do padrão é feita com base numa característica mensurável.

No método sintático, linguístico ou estrutural, a informação estrutural que descreve cada padrão é importante, e o processo de reconhecimento inclui, além da capacidade de designar o padrão para uma classe, a capacidade de descrever os aspectos do padrão de tal forma que ele não possa ser designado para outra classe.

O método sintático ou estrutural trabalha, principalmente, com problemas onde os padrões são considerados complexos e o número de características é alto (FU, 1982). Cada padrão é descrito em termos de subpadrões. Cada subpadrão é descrito em termos de suas partes. Sendo o mais simples dos subpadrões chamados de padrão primitivo (primitiva). A descrição de cada primitiva pode ser determinística ou estatística, e o reconhecimento das primitivas é freqüentemente baseado no método da decisão teórica. Do mesmo modo que a gramática de uma linguagem forma frases e sentenças pela concatenação de palavras, e palavras pela concatenação de letras, esse método estrutura os padrões na forma de várias composições de subpadrões.

Como já mencionado, no método sintático ou estrutural, o reconhecimento é feito através de uma descrição estrutural do padrão. Por exemplo, uma determinada cena A que apresente um círculo C e um retângulo R, na descrição estrutural pode ter o círculo dividido em dois arcos: a_1 e a_2 , e o retângulo dividido em quatro linhas: l_1 , l_2 , l_3 e l_4 . A descrição estrutural pode ser representada como mostrada na FIGURA 2.1.

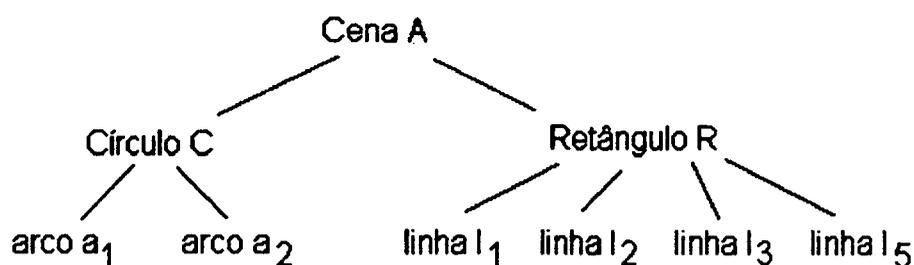


FIGURA 2.1: Descrição Estrutural Hierárquica da Cena A

Fonte: FU, 1982

2.5 Sistemas de Reconhecimento de Padrões Sintáticos

Geralmente, um Sistema de Reconhecimento de Padrões Sintáticos (FIGURA 2.2) é composto de um processo de análise e outro de reconhecimento.

O processo de análise é o responsável pela seleção de primitivas e pela inferência gramatical, visando extrair as informações estruturais relevantes do padrão para que possa ser realizado o processo de reconhecimento (FU, 1982).

O processo de reconhecimento envolve quatro etapas:

- pré-processamento: responsável pela codificação e aproximação do padrão, bem como, pela filtragem e restauração;
- segmentação ou decomposição do padrão;
- reconhecimento de primitivas;
- análise sintática.

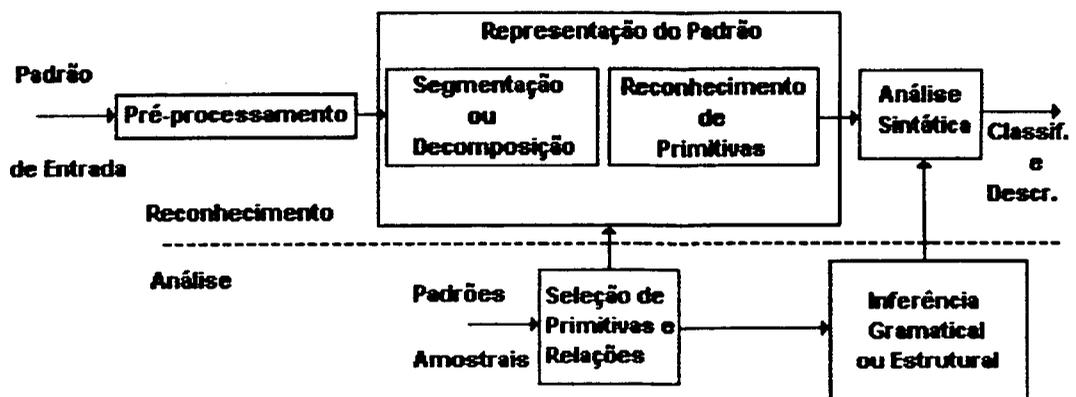


FIGURA 2.2: Diagrama de um Sistema de Reconhecimento de Padrões Sintáticos
Fonte: FU, 1982

2.6 Reconhecimento de Padrões através de Redes Neurais

No reconhecimento de padrões clássico, é utilizada a percepção para reconhecer um objeto, e o reconhecimento é feito somente se o objeto for muito similar ao padrão. Para PAO (1989), o reconhecimento de padrões é feito baseado nessa teoria e na inteligência artificial, que ele denomina de reconhecimento de padrões adaptativo.

Reconhecimento de padrões adaptativo é, portanto, uma metodologia que surgiu da adição de reconhecimento de padrões clássicos com o processamento distribuído paralelo (redes neurais) (PAO, 1989).

Os seres humanos normalmente processam alguns problemas complexos; como reconhecimento de imagens e de discursos, de uma maneira mais rápida que as máquinas. Os neurônios do cérebro humano têm, porém, uma velocidade de poucos milissegundos; portanto, são necessárias apenas algumas centenas de passos de processamento para resolver estes problemas. Os computadores mais modernos, utilizando técnicas de Inteligência Artificial, necessitam de milhões de operações para resolver tarefas semelhantes. Desta comparação, pode-se imaginar que as estruturas necessárias para resolver esses problemas encontram-se relacionadas com a estrutura das conexões existentes entre os neurônios. Da noção de que é possível resolver problemas complexos, através de elementos processadores simples interconectados, é que surgiram as redes neurais artificiais (KHANNA, 1990).

Ao contrário do que é costume em programas computacionais tradicionais, onde um problema é dividido em pequenos passos e cada um deles é resolvido, para alcançar a solução, as redes neurais não trabalham sobre o problema, desenvolvendo um algoritmo para cada elemento processador. Desta forma, para estudar o comportamento das redes, devem ser consideradas as entradas, as transformações e as saídas da rede (NELSON e ILLINOWORTH, 1990).

Os valores de entrada de uma rede são, geralmente, armazenados numa primeira camada de neurônios, cuja única função é preservar esses valores. As redes trabalham unicamente com valores de entrada numéricos. Algumas vezes, é necessário fazer um pré-processamento (por exemplo, sinais

luminosos podem ser convertidos, através de câmeras, para sinais analógicos). Também pode ser necessário converter os valores para uma determinada escala. Os sinais positivos, de excitação, são tão importantes quanto os sinais de inibição (negativos). Algumas redes utilizam um sinal de entrada fixo, chamado de termo de desvio. Adicionalmente, algumas redes dinâmicas possuem um termo esquecimento, e, dessa forma, as saídas não continuam a ser influenciadas por entradas que não são mais importantes.

As entradas que chegam a cada neurônio são somadas, tornando-se o produto interno dos pesos e das entradas. Porém, em determinadas estruturas esta soma pode ser mais complicada, sendo adicionada à soma anterior, ou necessitando ser normalizada, etc.

A camada de saída transfere a informação da rede para o ambiente. Como a camada de entrada, ela pode simplesmente transferir as saídas ou pode, da mesma forma que nas entradas, ser necessário diferentes transformações.

A relação entre a soma das entradas de um neurônio e a saída é dada pela função de transferência, ou de ativação. A soma das entradas é o parâmetro da função de transferência que vai especificar o valor de saída. Várias funções são utilizadas, entre elas a função degrau, a função rampa, a função sigmóide, etc. As funções lineares não são de muita utilidade.

Além da função de transferência, o estado de memória da rede define quais são as suas saídas. Este estado de memória é dado pelos pesos associados a cada interconexão dos neurônios. Os pesos iniciais são determinados por algoritmos, ou randomicamente. Através dos algoritmos de aprendizado, os pesos são modificados. O algoritmo de programação para trás, ou seja, para a camada anterior, é um dos métodos mais utilizados para a aprendizagem.

O número de elementos processadores ou neurônios a serem utilizados nas camadas externas depende do número de entradas e de saídas. Nas camadas internas da rede, o número de neurônios a utilizar é determinado por experiências. Sempre que os padrões de entrada são bastante diferentes dos padrões de saída, camadas internas são necessárias. A habilidade de processar informações aumenta com o número de camadas.

Outro fator importante, na topologia da rede, é o modo como as saídas de um elemento estão ligadas aos outros elementos. Se os elementos passam as saídas somente para a próxima camada da rede, é chamada de alimentada para frente. Redes com alimentação para trás permitem que os elementos de uma camada alimentam os elementos da camada anterior. Em determinados casos, as saídas de um elemento podem alimentar neurônios da mesma camada. Esse caso é chamado de alimentação lateral.

Cada estrutura de rede, constituída pelos elementos processadores, número de camadas, número de neurônios, forma de alimentação, etc., é apropriada para um tipo de problema. A primeira tarefa a definir é investigar a estrutura adequada para o problema.

2.7 Conclusão

Verifica-se uma dicotomia entre o método de decisão teórica e o método sintático, sendo essa mais uma questão teórica do que prática. Muitas técnicas de preprocessamento e segmentação são úteis para os dois métodos. A escolha das técnicas a serem aplicadas depende mais do tipo de padrão em estudo do que do método de reconhecimento a ser aplicado.

O problema de seleção de características, no método de decisão teórica, e o problema de seleção de primitivas, no método estrutural ou sintático, são similares na sua essência. A diferença consiste em que as primitivas, no método sintático, representam subpadrões, e as características, no método de decisão teórica, podem ser qualquer conjunto de medidas numéricas tomadas do padrão.

Quando a informação estrutural explícita sobre os padrões não é considerada fundamental, e o problema é de classificação e não de descrição, não existe necessidade de usar-se o método sintático. Por outro lado, quando os padrões apresentam muita informação estrutural e o problema exige classificação e descrição, torna-se necessário usar o método estrutural.

Da adição de processamento distribuído paralelo ao reconhecimento de padrões clássico, surge o que convencionou-se chamar de reconhecimento de padrões adaptativo (PAO, 1989). Suas principais características são a capacidade de adaptar-se a situações onde os padrões se apresentam distorcidos e modificar o processo de reconhecimento, de acordo com as mudanças do ambiente.

3. CONJUNTOS DIFUSOS

3.1 Introdução

As técnicas de reconhecimento de padrões, que buscam a estrutura dos dados, baseando-se no fato de que eles trazem agregados as informações que os geraram, são utilizadas em processos de classificação.

Os métodos convencionais utilizados para classificação de imagens apresentam problemas, principalmente, com relação à delimitação de classes e à própria resposta espectral dentro de uma mesma classe. As imprecisões e incertezas verificadas na delimitação de classes são decorrentes do problema de que classes distintas podem apresentar comportamentos espectrais semelhantes, trazendo, como consequência, ambigüidades nos processos de classificação.

A teoria dos conjuntos difusos fornece um instrumento adequado para modelar situações em que ocorram imprecisões ou incertezas (ZADEH, 1965). Pode, portanto, ser utilizada para o tratamento de incertezas e imprecisões em problemas de classificação. Em uma representação difusa, as classes podem ser definidas por conjuntos difusos cujos elementos são os pixels.

De acordo com a teoria dos conjuntos difusos, um conjunto não tem limites nitidamente definidos e um elemento pode pertencer parcialmente a um conjunto ou pertencer a mais de um conjunto ao mesmo tempo. Portanto, a introdução dessa teoria, no processo de classificação de imagens digitais, conduzirá a uma menor perda de informações, permitindo identificar pixels que são bem representativos de cada classe e pixels que são mistos ou intermediários.

3.2 Definição

A teoria clássica dos conjuntos caracteriza-se pelo fato de que um elemento pertence ou não pertence a um conjunto, não existindo uma situação intermediária. Considere-se que X seja um conjunto clássico de objetos, denominado universo, cujos elementos são denotados por x , e que A seja um subconjunto de X . Uma função f_A é definida por:

$$\begin{aligned} f_A(x) &= 1 \text{ se e somente se } x \in A \\ f_A(x) &= 0 \text{ se e somente se } x \notin A \end{aligned}$$

f_A é a função característica de X em $\{0,1\}$, sendo $\{0,1\}$ chamado de conjunto de avaliação.

No entanto, encontra-se, no mundo real, uma série de situações em que a modelagem clássica dos conjuntos não é adequada. Isso porque esses conjuntos não apresentam limites bem definidos, e a pertinência de um elemento ao conjunto não pode ser especificada por um critério binário. Existem casos que se encontram em uma situação intermediária. Para tratá-los, ZADEH (1965) desenvolveu a teoria dos conjuntos difusos.

Segundo essa teoria, conjunto difuso é definido como:

Se X é uma coleção de objetos x , então um conjunto difuso A em X é um conjunto de pares ordenados: $A = \{(x, f_A(x)) / x \in X\}$. A função $f_A(x)$ é chamada função de pertinência, ou seja, o valor que é o grau de pertinência de x em A , sendo a $f_A(x)$ uma função em $[0,1]$ (PAO, 1989).

Exemplo: Considere-se o conjunto de números reais próximos a 10. $A = \{(x, f_A(x)) / f_A(x) = (1 + (x - 10)^2)^{-1}\}$. A representação gráfica da função de pertinência é mostrada na FIGURA 3.1.

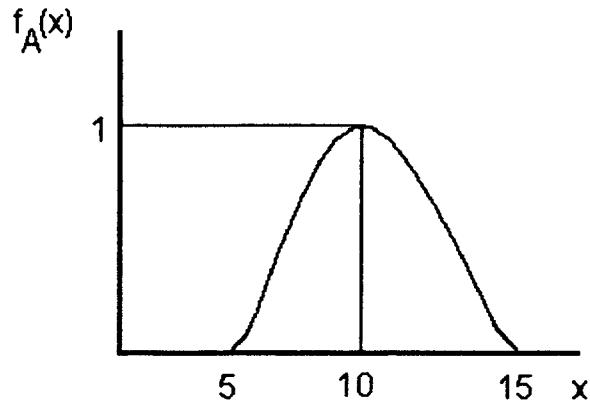


FIGURA 3.1: Grau de Pertinência dos Números Reais Próximos a 10
 Fonte: ZIMMERMANN, 1985

3.3 Definições Básicas e Operações da Teoria dos Conjuntos Difusos

As definições a seguir, extraídas de DUBOIS e PRADE (1980), são utilizadas no decorrer deste trabalho.

- Denomina-se **Conjunto Difuso Convexo** todo conjunto difuso em que, para dois pontos quaisquer:

$$f_A(\lambda x_1 + (1 - \lambda) x_2) \geq \text{Min}(f_A(x_1), f_A(x_2)), \quad \forall x_1, x_2 \in X \text{ e } \forall \lambda \in [0, 1]$$

- **Conjunto Difuso Normalizado** é todo conjunto difuso cujo maior grau de pertinência é 1 (um).

- Chama-se **Número Difuso** a todo conjunto difuso convexo e normalizado em que:

- existe um e somente um ponto x_0 para o qual o valor da função de pertinência seja 1;
- a função de pertinência que define o conjunto é contínua por partes.

- Denomina-se **Corte de Nível α** ao conjunto clássico formado pelos elementos x cuja função de pertinência seja maior ou igual a α .

$$A = \{x \in X / f_A(x) \geq \alpha\}$$

- O suporte de um conjunto difuso A, $S(A)$, é o conjunto de todo $x \in X$ tal que $f_A(x) > 0$.

- A Cardinalidade $|A|$ de um conjunto difuso é definida como:

$$|A| = \sum f_A(x), \text{ onde } x \in X$$

- A Igualdade de dois conjuntos difusos A e B ocorre, se e somente se, para todo e qualquer $x \in X$, tem-se $f_A(x) = f_B(x)$.

- A Função de Pertinência do Complemento de um conjunto difuso A é definida como:

$$f_{cA}(x) = 1 - f_A(x), x \in X$$

- A Função de Pertinência $f_C(x)$ da Intersecção $C = A \cap B$, é definida por:

$$f_C(x) = \text{Min}(f_A(x), f_B(x)), x \in X.$$

- A função de Pertinência $f_D(x)$ da União $D = A \cup B$, é definido por:

$$f_D(x) = \text{Max}(f_A(x), f_B(x)), x \in X.$$

- O Produto Cartesiano de conjuntos difusos é definido como: sejam A_1, \dots, A_n conjuntos difusos em X_1, \dots, X_n . O produto cartesiano é o conjunto cartesiano no espaço produto $X_1 * X_2 * \dots * X_n$, com função de pertinência dada por:

$$f_{(A_1 * \dots * A_n)}(x) = \text{MIN}_i \{ f_{A_i}(x_i) / x = x_1, \dots, x_n \text{ e } x_i \in X_i \}$$

- Denomina-se m-ésima Potência de um conjunto difuso A, ao conjunto difuso com função de pertinência dada por:

$$f_{A^m}(x) = [f_A(x)]^m, x \in X$$

- A Soma Algébrica (Soma Probabilística), $C = A + B$ é definida como:

$$C = \{(x, f_{A+B}(x)) / x \in X\}, \text{ onde } f_{A+B}(x) = f_A(x) + f_B(x) - f_A(x) * f_B(x).$$

- A Soma Limitada, $C = A \oplus B$ é definida como:

$$C = \{(x, f_{A \oplus B}(x)) / x \in X\}, \text{ onde } f_{A \oplus B}(x) = \text{Min}(1, f_A(x) + f_B(x)).$$

- A Diferença Limitada, $C = A - B$ é definida como:

$$C = \{(x, f_{A-B}(x)) / x \in X\}, \text{ onde } f_{A-B}(x) = \text{Max}(0, f_A(x) + f_B(x) - 1).$$

- O Produto Algébrico de dois conjuntos difusos, $C = A * B$ é definido como:

$$C = \{(x, f_{A*B}(x)) / x \in X\}, \text{ onde } f_{A*B}(x) = f_A(x) * f_B(x).$$

- Seja $X = \{x_1, \dots, x_n\}$ um conjunto finito, e V_{cn} o conjunto de todas as matrizes reais $c \times n$, onde c é um inteiro e $2 < c < n$. A matriz $\tilde{U} = \{[f_{ki}] \in V_{cn}\}$ é chamada uma partição c -difusa se satisfaz as seguintes condições:

$$\bullet f_{ki} \in [0, 1]; \quad 1 \leq k \leq c, \quad 1 \leq i \leq n$$

$$\bullet \sum_{k=1}^c f_{ki} = 1; \quad 1 \leq i \leq n$$

$$\bullet 0 < \sum_{i=1}^n f_{ki} < n; \quad 1 \leq k \leq c.$$

3.4 Funções de Pertinência

A função de pertinência é utilizada para medir o grau de pertinência a um conjunto, ou seja, ela reflete o conhecimento em relação à intensidade com que um elemento pertence a um conjunto.

Para um conjunto difuso normalizado, o grau de pertinência assume um valor no intervalo $[0, 1]$ (PAO, 1989).

3.5 Estimação de Funções de Pertinência

A forma, os parâmetros e o domínio da função são pontos considerados importantes na estimação de funções de pertinência (DEVI e SARMA, 1985).

Os métodos freqüentemente utilizados são: o baseado no consenso de especialistas e o baseado em histograma.

3.5.1 Método baseado no Consenso de Especialistas

Neste método, a função de pertinência é obtida com base em opiniões subjetivas de especialistas da área em questão. Para tanto, são feitas entrevistas com especialistas, onde o objetivo é valorar declarações lingüísticas. Dada uma declaração do tipo X é Y , o especialista deve declarar sua concordância ou não com essa afirmação. A concordância pode ser expressa na forma binária (sim ou não) ou na forma multi-valorada (por exemplo, numa escala de 0 a 10).

Após a obtenção das declarações dos especialistas, são calculadas as freqüências relativas (caso binário) ou a média dos graus de concordância (caso multi-valorado). Em seguida, é construído um gráfico dos pontos obtidos, e ajustada uma função, estimando-se os parâmetros, por exemplo, através dos mínimos quadrados. Freqüentemente, essa função é normalizada.

3.5.2 Método baseado em Histograma

No método baseado em histograma, primeiramente, é construído um histograma que descreve os dados envolvidos. O número de classes do histograma, para um nível de significância de 0.005, é obtido através da seguinte fórmula (DEVI e SARMA, 1985):

$$m = 1.87(n - 1)^{2/5} \quad (3.1)$$

Onde: m = número de classes
 n = tamanho da amostra.

A função de pertinência a partir do histograma pode ser estimada utilizando-se uma função racional, onde os parâmetros são ajustados usando-se o método dos mínimos quadrados, sendo que a função deve ser normalizada.

Pode-se, também, obter a função de pertinência baseada em histograma de uma outra forma, onde, inicialmente, a função densidade de probabilidade ($p(x)$) é estimada. Após, estima-se a função de pertinência através de:

$$f(x) = \beta p(x), \quad \text{se } \beta p(x) \leq 1$$

$$1, \quad \text{se } \beta p(x) > 1 \quad (3.2)$$

Onde: β = constante, que é um parâmetro de ajuste.

3.6 Medidas de Possibilidade

Uma medida de possibilidade Π (ZADEH, 1973) é uma função de $\wp(X)$ - o conjunto de subconjuntos ordinários de X - para $[0,1]$ tal que:

- 1) $\Pi(\emptyset) = 0; \Pi(X) = 1$
- 2) Para qualquer coleção $\{A_i\}$ de subconjuntos de X ,
 $\Pi(\cup_i A_i) = \sup_i \Pi(A_i)$

Uma medida de possibilidade pode ser construída a partir de uma distribuição de possibilidade, isto é, uma função π a partir de X para $[0,1]$ tais que $\sup_{x \in X} \pi(x) = 1$ (condição de Normalização).

3.6.1. Possibilidade e Conjuntos Difusos

Sejam A e v , respectivamente, um conjunto não difuso de X e uma variável sobre X . v assumir valores em A indica que qualquer elemento em A pode, possivelmente, ser um valor de v e que qualquer elemento não pertencente a A não pode ser um valor de v . v assumir valor em A pode ser interpretado como uma distribuição de possibilidade π definida para X , a qual associa para cada x a possibilidade de que x seja um valor de v :

$$\Pi(v = x) = \pi(x) = \begin{cases} 1 & \text{se } x \in A \\ 0 & \text{caso contrário} \end{cases} \quad (3.3)$$

Sendo A um conjunto difuso representando uma restrição difusa sobre um valor possível de v :

$$\Pi(v = x) = \pi(x) = \mu_A(x) \quad (3.4)$$

Uma distribuição de possibilidade pode ser vista como um conjunto difuso e, portanto, distribuições de possibilidade podem ser tratadas através da combinação de regras de conjuntos difusos e, particularmente, de restrições difusas (ZADEH, 1973):

3.6.2 Possibilidade de um Evento Não Difuso

Seja π uma distribuição de possibilidade induzida por um conjunto difuso F em X . Seja A um conjunto não difuso de X ; a possibilidade que x pertença a A é $\Pi(A)$, onde Π é uma medida de possibilidade induzida através de π :

$$\Pi(A) = \sup_{x \in A} \mu_F(x) = \sup_{x \in A} \pi(x) \quad (3.5)$$

Similarmente, se p é uma distribuição de probabilidade sobre X , a probabilidade de que x pertença a A é:

$$P(A) = \int_A dP = \begin{cases} \int_A p(x) dx & \text{se } X = \mathfrak{R} \\ \sum_{x \in A} p(x) & \text{se é finito} \end{cases} \quad (3.6)$$

3.6.3 Princípio de Consistência

De acordo com DUBOIS e PRADE (1980), o grau de possibilidade de um evento é maior ou igual ao seu grau de probabilidade, o qual deve ser maior do que o seu grau de necessidade.

O conceito de necessidade estabelecido por aqueles autores está relacionado com os conceitos de inevitável e possível: "o que é provável é certamente possível e o que é inevitável (necessário) é certamente provável".

3.7 Algoritmos Difusos

Algoritmo difuso é um conjunto ordenado de passos cuja execução leva a uma solução aproximada para um problema específico (ZADEH, 1968).

Nesse sentido, a maioria das atividades executadas pelo ser humano, como, por exemplo, dirigir um carro, procurar um objeto, reconhecer um padrão, etc., é resultante da aplicação de um algoritmo difuso.

Nos algoritmos difusos encontram-se três tipos de instruções: comandos de atribuição, comandos condicionais difusos e comandos de ação incondicional.

Nas instruções de atribuição, um possível valor difuso é atribuído a uma variável. Como exemplo:

- x é igual a aproximadamente 10;
- y não é muito pequeno e nem muito grande.

Em instruções condicionais difusas, um possível valor difuso é atribuído a uma variável, ou uma ação é executada, dependendo de uma condição difusa. Por exemplo:

- se x é grande
então y é pequeno
senão y não é pequeno
- se x é muito menor que 10
então pare

Nas instruções de ação incondicional, uma operação matemática ou ação difusa é executada. Exemplo:

- diminua " x " lentamente;
- multiplique " x " por si mesmo poucas vezes.

Assim, uma instrução é dita difusa quando nela aparece um conjunto difuso, e isso faz com que exista algo impreciso ou vago em sua execução. Num algoritmo difuso, nem todas as instruções são necessariamente difusas.

Um algoritmo para manipular conjuntos difusos é formado por instruções difusas, que são executadas de forma determinística por meio de combinações algébrico-lógicas de conjuntos difusos. O resultado consiste de conjuntos difusos obtidos a partir de resultados difusos intermediários e de conjuntos difusos que aparecem em instruções difusas.

Uma instrução determinística é escolhida para cada instrução difusa existente em um algoritmo difuso. Essa instrução determinística é considerada como a melhor interpretação da instrução difusa, e é realmente executada.

A execução de uma instrução difusa pode ser considerada como a execução paralela de um número infinito de instruções determinísticas. Dessa forma, um algoritmo difuso pode ser visto como uma família de algoritmos não difusos que são executados em paralelo, sendo, ao final, somente um deles escolhido para execução, ou como um único algoritmo que processa dados difusos de uma forma determinística.

Na realidade, pode ser considerada a existência de dois tipos de algoritmos difusos. O primeiro tipo consiste de algoritmos convencionais que realizam a implementação de modelos difusos. O objetivo de tais algoritmos é deduzir a difusão das saídas, conhecendo-se as das entradas do modelo. O que se obtém são distribuições de possibilidade dos valores de saída não difusos do processo modelado. O segundo tipo de algoritmo baseia-se no fato que, quando o homem está diante de uma instrução difusa, a ação que ele realiza não será difusa. Nesse tipo de algoritmo, existem descrições difusas de ações não difusas. O resultado é sempre uma seqüência de ações precisas.

ZADEH (1973) definiu quatro tipos de algoritmos difusos, cada um correspondendo a um tipo particular de aplicação:

- algoritmo definicional difuso: consiste de um conjunto de instruções difusas que definem um conjunto difuso em termos de outros conjuntos difusos ou de um procedimento para computar o grau de pertinência de cada elemento do universo no conjunto sob definição. Usado como um dispositivo de identificação, esse tipo de algoritmo leva a um resultado não difuso;

- algoritmo geracional difuso: serve para gerar, ao invés de definir um conjunto difuso. Como exemplo, tem-se o algoritmo para gerar caracteres escritos à mão;

- algoritmo comportamental e relacional difuso: serve para descrever relações entre variáveis difusas. Um algoritmo comportamental difuso é um algoritmo relacional, que é usado para o fim específico de descrições aproximadas do comportamento do sistema. Geralmente esse algoritmo gera saídas difusas que, se forem incorporadas a um sistema de controle, devem ser "desfuzificadas".

- algoritmo decisional difuso: apresenta como saída uma descrição aproximada de uma estratégia ou regra de decisão. Devido a esse fato, seu resultado nunca é difuso.

3.8 Lógica Difusa

Existem algumas proposições que representam problemas, os quais, para serem resolvidos, não possuem uma estrutura definida na matemática clássica nem na teoria das probabilidades. Esses problemas os seres humanos são capazes de resolver, através do uso do chamado raciocínio aproximado ou difuso, que pode ser modelado através da lógica difusa.

As lógicas, como base para o raciocínio, podem ser distinguidas por três itens: valores verdade, vocabulários (operadores) e processo de raciocínio.

Uma característica típica da lógica clássica é a presença da decisão dicotômica, onde os valores verdade são 0 ou 1 e o vocabulário é definido através desses valores verdade sob a forma de tabelas verdade. A lógica difusa baseia-se nas lógicas multi-valoradas, em que os valores verdade variam no intervalo $[0,1]$. Segundo ZADEH (1973), a lógica difusa é uma extensão da lógica multi-valorada, em que os valores verdade são variáveis lingüísticas.

No mundo real, um fato não pode ser caracterizado somente como verdadeiro ou falso, mas sim como verdadeiro, mais ou menos verdadeiro, mais ou menos falso, etc. A similaridade existente entre essas expressões e os valores de uma variável lingüística leva à definição de variável lingüística verdade. O tratamento da verdade como uma variável lingüística conduz à lógica difusa, que fornece a base para o raciocínio difuso.

Raciocínio Difuso, portanto, é o processo ou processos pelos quais uma conclusão, possivelmente imprecisa, é deduzida de uma coleção de premissas imprecisas. Tal raciocínio é, na maioria dos casos, antes qualitativo que quantitativo por natureza, e quase sempre cai fora da aplicabilidade da lógica clássica (DUBOIS e PRADE, 1980).

3.9 Conclusão

A teoria clássica dos conjuntos, por sua característica dicotômica, apresenta limitações em seu uso para a modelagem de muitos problemas do mundo real. Existem muitas situações nas quais os dados contêm imprecisões ou não se consegue uma distinção entre eles, podendo um elemento pertencer a mais de um conjunto. A teoria dos conjuntos difusos fornece uma ferramenta mais adequada para modelar esses tipos de dados. Sua aplicação num processo de classificação permitirá não só identificar os elementos que pertencem a cada uma das classes, como também aqueles que apresentam misturas de classes.

4. PROCESSAMENTO DIGITAL DE IMAGENS

4.1 Introdução

Sensoriamento Remoto pode ser definido como a aplicação de dispositivos que, colocados em aeronaves ou satélites, permitem obter informações sobre objetos ou fenômenos na superfície da terra (AMARAL, 1990).

Nas últimas três décadas, as técnicas de sensoriamento remoto evoluíram bastante e as pesquisas desenvolvidas nessa área têm proporcionado subsídios para identificar, mapear e cadastrar os recursos naturais da terra.

Os produtos obtidos por sensoriamento remoto podem ser encontrados no formato fotográfico ou no formato digital.

Durante a última década, tem-se notado um crescente interesse no uso de dados de imagem digital, o que tem levado ao desenvolvimento de sistemas para processar esses dados (DOWMAN, EBNER e HEIPKE, 1992).

4.2 Definição

Processamento Digital de Imagens é o conjunto de procedimentos relativos à manipulação e análise de imagens através do computador (QUINTANILHA, 1990). Esses procedimentos englobam a entrada de dados digitais, o realce, a análise estatística e a geração de saídas, que podem ser imagens em tons cinzas ou coloridas.

O principal objetivo do uso das técnicas de processamento digital de imagens é realçá-las, melhorando a sua qualidade e o seu aspecto. Dessa forma, obtêm-se melhores subsídios para a sua interpretação e, ainda, podem ser submetidas a outros processamentos.

As técnicas de processamento digital de imagens podem ser agrupadas em: técnicas de pré-processamento, técnicas de realce e técnicas de classificação.

4.3 Técnicas de Pré-processamento

Os dados de sensoriamento remoto orbital são obtidos através de dispositivos que apresentam limitações em termos de resolução espacial, espectral, temporal e radiométrica. Esse fato acarreta a ocorrência de erros no processo de aquisição dos dados e pode causar degradação de sua qualidade. Esses erros podem trazer conseqüências na precisão das análises posteriores a que serão submetidos esses dados. Toma-se, portanto, necessário pré-processá-los, antes de analisá-los, com a finalidade de remover ou diminuir esses erros.

Segundo JENSEN (1986), os processos de restauração de imagens consistem na correção de distorções, degradação e ruídos introduzidos durante o imageamento, produzindo uma imagem que apresenta características de energia radiante que se aproximam das existentes na cena original, tanto geométrica como radiometricamente.

O pré-processamento consiste na realização de operações sobre as imagens, para corrigir as distorções existentes ou melhorar o desempenho de algoritmos computacionais que deverão ser usados em uma fase posterior. Entre as operações de pré-processamento, tem-se a eliminação de ruído, a correção atmosférica e o registro.

4.3.1 Eliminação de Ruído

Os sensores remotos utilizam-se de detectores para converter a radiância em um nível de cinza. Muitas vezes, um dos detectores pode falhar durante o imageamento e isso resulta em uma linha ou parte de uma linha com

nível de cinza igual ou próximo a zero para todos os pixels. Esse fenômeno é chamado de ruído.

Imagens que apresentam ruído devem ser submetidas a um processo de correção radiométrica, para melhorar a sua qualidade. Como o dado não foi coletado, é impossível restaurá-lo. Segundo NOVO (1988), qualquer que seja a técnica de correção radiométrica, esta sempre acarretará em alteração dos dados originais. Muitas vezes, aplicação descuidada de técnicas de correção radiométrica pode levar a uma total degradação dos dados originais. Por esse motivo, a natureza dos dados deve ser conhecida, para que os procedimentos mais adequados possam ser selecionados.

A eliminação do ruído é feita pela estimação do nível de cinza para cada pixel que apresenta ruído. Inicialmente, a imagem deve ser analisada, a fim de detectar as linhas que apresentam ruído (normalmente, com uma seqüência de pixels com níveis de cinza próximos a zero e diferentes dos níveis de cinza das linhas anterior e posterior). Uma vez detectado o ruído, ele deve ser eliminado. Um dos métodos mais empregados para isso é estimar o nível de cinza do pixel através da média dos níveis de cinza dos pixels na posição correspondente nas linhas anterior e posterior à que apresenta o ruído. Dessa forma, se $NC(i, j)$ é o nível de cinza do pixel com ruído na linha i e coluna j , o nível de cinza estimado para esse pixel (NC_{est}) será dado por:

$$NC_{est}(i, j) = INT\left(\frac{NC(i-1, j) + NC(i+1, j)}{2}\right) \quad (4.1)$$

Onde: $NC(i-1, j)$ = nível de cinza do pixel na linha anterior

$NC(i+1, j)$ = nível de cinza do pixel na linha posterior

Segundo JENSEN (1986), o resultado da aplicação desse método é uma imagem consistindo de dados interpolados. Esses são visualmente muito mais interpretáveis do que linhas escuras estendendo-se sistematicamente através da imagem.

4.3.2 Correção Atmosférica

A radiação solar não é afetada quando se propaga no vácuo. Entretanto, o contato com a atmosfera pode ocasionar um espalhamento ou absorção, resultando em distorções radiométricas nos dados de sensoriamento remoto. O espalhamento atmosférico causa um aumento no valor do brilho e afeta principalmente a região do visível (entre 0,4 e 0,7 μm), enquanto a absorção atmosférica pelo vapor da água e outros gases diminui o valor do brilho e afeta a radiação dos comprimentos de onda maiores que 0,8 μm .

Os dados afetados pelos efeitos atmosféricos, muitas vezes, necessitam ser corrigidos, pois podem ocasionar distorções no processo de análise.

A técnica mais comumente usada para a correção atmosférica baseia-se na suposição que o efeito da atmosfera é aditivo, sendo, portanto, consequência do espalhamento. Considera ainda que o efeito do espalhamento diminui à medida que aumenta o comprimento de onda. Como teoricamente a radiância de uma região de sombra ou de um lago deve ser nula, essas áreas são utilizadas para determinar a magnitude do sinal que é adicionado à imagem. Se apresentarem valor acima de zero, esse valor deverá ser subtraído de todos os pixels da área escolhida, em cada uma das bandas do visível. Os valores de brilho de uma banda visível são então plotados em relação aos valores correspondentes em uma banda do infravermelho. Usando o método dos mínimos quadrados, é feito o ajustamento de uma reta para representar esses dados. Se não existe efeito do espalhamento atmosférico, a reta ajustada deve passar pela origem. Entretanto, isso raramente acontece, e o valor do intercepto representa o montante de desvio causado pelo espalhamento e deve ser subtraído da banda original para toda a cena.

Outra maneira de realizar a correção atmosférica é analisar o histograma dos níveis de cinza de cada banda e considerar o valor mínimo de nível de cinza encontrado como o efeito do espalhamento atmosférico. Esse valor é então subtraído de toda a cena.

4.3.3 Registro de Imagens

O registro de imagens é o processo de alinhamento por rotação e translação. Esse processo faz com que duas imagens, de geometria similar e com os mesmos conjuntos de objetos sejam posicionadas de forma coincidente, uma em relação à outra, de modo que os elementos correspondentes da mesma área do solo apareçam no mesmo local nas imagens registradas (JENSEN, 1986). O registro é, pois, a superposição de imagens, de modo que exista coincidência espacial entre os pontos que correspondam aos mesmos objetos.

MASCARENHAS e VELASCO (1989) afirmam que o registro de imagens é importante quando:

- têm-se imagens obtidas por diferentes sensores e se deseja saber a resposta do mesmo ponto aos diversos sensores;
- têm-se imagens obtidas em diferentes épocas ou mesmo diferentes instantes de tempo;
- têm-se imagens tomadas de posições diferentes e se pretende obter informação tridimensional da cena;
- deseja-se registrar uma imagem obtida por sensores com um mapa.

Um passo importante, numa operação de registro, é determinar a transformação geométrica que relaciona as duas imagens. Isso pode ser feito pelo uso de informação adicional ou através do uso de pontos de controle. Pontos de controle são pontos, nas duas imagens, que correspondem ao mesmo objeto. A escolha de um número conveniente de pontos de controle permite determinar as funções que mapeiam as coordenadas de uma imagem na outra.

Para a realização do registro imagem versus imagem, inicialmente são definidas uma imagem de referência e outra a ser ajustada. A seguir, são determinados os pontos de controle. Um ponto de controle é um ponto da cena do qual se sabe a posição em ambas as imagens. BRUM (1989) afirma que é importante observar-se que a quantidade de pontos de controle e sua distribuição

sobre a imagem são parâmetros fundamentais para que se consigam bons resultados. Esses pontos de controle são utilizados para realizar o ajuste de polinômios, que mapeiam as coordenadas da imagem a ser ajustada em função das coordenadas da imagem de referência. O número mínimo de pontos de controle para realizar o ajuste depende do grau dos polinômios escolhidos (normalmente grau 1 ou 2). Polinômios de grau 1 necessitam de um mínimo de 3 e polinômios de grau 2 de um mínimo de 6 pontos de controle. Considerando que x_1 e y_1 são as coordenadas da imagem de referência e x_2 e y_2 são as coordenadas da imagem a ser ajustada, os polinômios são os seguintes:

De grau um:

$$\begin{aligned}x_2 &= a_0 + a_1x_1 + a_2y_1 \\y_2 &= b_0 + b_1x_1 + b_2y_1\end{aligned}\tag{4.2}$$

De grau dois:

$$\begin{aligned}x_2 &= a_0 + a_1x_1 + a_2y_1 + a_3x_1^2 + a_4y_1^2 + a_5x_1y_1 \\y_2 &= b_0 + b_1x_1 + b_2y_1 + b_3x_1^2 + b_4y_1^2 + b_5x_1y_1\end{aligned}\tag{4.3}$$

A estimação dos parâmetros é feita utilizando-se o método dos mínimos quadrados. A quantidade de pontos de controle a ser utilizada depende da variação existente entre as duas imagens. Se as distorções entre elas forem pequenas, um menor número de pontos será requerido. Entretanto, é importante que esses pontos estejam distribuídos por toda a área da imagem. Normalmente, são escolhidos mais pontos de controle que os requeridos para o ajuste. Uma análise de resíduos irá determinar a precisão do ajuste e a conseqüente qualidade do registro. Os pontos de controle que não foram utilizados no ajuste fornecem maiores subsídios para se determinar a sua precisão.

Estimadas as funções de mapeamento, o passo seguinte é a realização do registro. Isso é feito pela criação de uma nova imagem, que corresponde à imagem a ser ajustada, registrada em relação à de referência. Significa que os objetos dessa nova imagem devem coincidir espacialmente com os objetos da imagem de referência, de modo que haja uma superposição entre as duas. Dessa forma, mesmo que a imagem original a ser ajustada tenha uma resolução espacial diferente da imagem de referência, isso não ocorrerá com a

imagem registrada. Ela terá, pois, o mesmo número de pontos e a mesma resolução espacial da imagem de referência.

Para a obtenção da imagem corrigida ou registrada, deve ser feita uma "reamostragem", ou seja, o cálculo dos novos níveis de cinza. Esses novos níveis são obtidos em função dos níveis de cinza da imagem original a ser ajustada, utilizando métodos de interpolação. Segundo SILVA et al in QUINTANILHA (1990), os métodos mais comuns para realizar a interpolação são:

- vizinho mais próximo (polinômio de grau zero): seleciona o nível de cinza do pixel mais próximo e o atribui ao pixel da imagem de saída. Esse método de reamostragem tem a vantagem de ser computacionalmente eficiente e de preservar o valor do pixel;

- interpolação bilinear: utiliza os valores de nível de cinza dos quatro vizinhos do pixel (ponderados pela distância deste a cada vizinho) para calcular seu valor de saída. Esse valor pode ser obtido por:

$$NC_s = \frac{\sum_{k=1}^4 \frac{NC_k}{(dist_k)^2}}{\sum_{k=1}^4 \left(\frac{1}{(dist_k)^2} \right)} \quad (4.4)$$

Onde: NC_s = nível de cinza de saída

NC_k = nível de cinza de cada vizinho

$dist_k$ = distância do pixel a cada vizinho

Segundo HARALICK (1973), retificação é o processo pelo qual a geometria de uma imagem torna-se planimétrica. Na realidade, trata-se do processo de registro imagem-mapa, que envolve o relacionamento das coordenadas dos pixels (em termos de linha e coluna) com as coordenadas correspondentes no mapa (posição em relação a um sistema de projeção de coordenadas geográficas). JENSEN (1986) afirma que esse é o mais preciso sistema de correção geométrica, tendo em vista que cada pixel pode ser referenciado não somente por sua linha e coluna numa matriz, mas também rigorosamente referenciado em graus ou metros numa projeção de mapa padrão.

O registro imagem-mapa deve ser realizado sempre que forem requeridas medidas precisas de área, direção e distância.

GREEN (1983) define duas operações básicas que devem ser realizadas para registrar uma imagem num mapa:

- identificar a relação geométrica entre a localização do pixel na imagem (linha e coluna) e a coordenada do mapa associado no mesmo ponto (x,y). É isso que irá estabelecer a natureza da transformação das coordenadas geométricas que deverá ser aplicada, para retificar ou realocar cada pixel da imagem de entrada original em sua posição na imagem retificada de saída. Esse processo é denominado interpolação espacial;

- determinar os valores do nível de cinza dos pixels. Não existe uma relação unívoca entre os valores de nível de cinza dos pixels de entrada e a localização dos pixels de saída. Muitas vezes, um pixel na imagem retificada da saída requer um valor referente a uma posição que não corresponde exatamente a uma coordenada de linha-coluna da grade de entrada. Quando isso ocorre, deve haver um mecanismo para determinar o valor de nível de cinza a ser atribuído ao pixel retificado. Esse processo é chamado de interpolação de intensidade.

Os procedimentos para a realização do registro imagem-mapa são similares ao registro imagem-imagem, com a diferença que os pontos de controle, quando marcados no mapa, referem-se a uma posição em relação a um sistema de coordenadas geográficas. Como saída, tem-se uma imagem geo-referenciada, de acordo com o sistema de projeção do mapa utilizado.

4.3.4 Aplicações das Técnicas de Préprocessamento

Existe um grande número de trabalhos em que foram aplicadas as técnicas de préprocessamento. O tipo de técnica a ser aplicada depende de muitos fatores, como a qualidade da imagem original, o número de imagens a serem utilizadas, o objetivo do trabalho, entre outros. A seguir, são relacionados trabalhos que utilizaram essas técnicas.

LAPOLLI, ALVES, LUZ e ZARDO (1993), visando à utilização de filtros para o realce de áreas urbanas, usaram imagens SPOT multiespectral e pancromática de 25/03/91, órbita ponto K713/J402, abrangendo uma área do município de Joinville/SC. Essas imagens foram registradas com 10 pontos de controle, com o ajuste sendo efetivado por um polinômio de grau 2. Mostraram que o registro de imagens garante o enquadramento e o ajuste entre elas, e que o uso dessa técnica preserva a característica da resolução da banda pancromática.

Na análise do vetor de mudanças para o monitoramento de ambientes costeiros, MICHALEK, WAGNER, LUCZKOVICH e STOFFLE (1993) utilizaram duas imagens LANDSAT TM-5 (órbita/ponto 8/46, de 02/02/1985 e 04/01/1989) da República Dominicana. A imagem de 1985 foi registrada num mapa em escala 1:50000, projeção UTM. Uma subcena da imagem contendo a área de estudo foi reamostrada. A imagem de 1989 foi então registrada na de 1985.

MARTINS, LUZ e SOARES (1993) estudaram as variações espaciais e temporais da linha de costa e da formação de bancos de areia entre Pontal do Sul e Ilha da Galheta, Paranaguá-PR. Utilizaram imagens do satélite LANDSAT TM-5, de 22/05/85, 23/05/91 e 10/07/91, bandas 1, 2 e 3. Para melhorar a qualidade das imagens, realizaram correção atmosférica, subtraindo o nível de cinza mínimo de toda a cena. Essas imagens foram depois realçadas e utilizadas num processo de classificação, sendo obtidos resultados satisfatórios.

PEZZI e PROVITINA (1993) utilizaram uma imagem LANDSAT-TM5, multiespectral, bandas 1 a 7, com localização WRS 232/66 na grade de referência, datada de 8 de julho de 1989, sobre o Estado de Rondônia, na região de Porto Velho. O objetivo do trabalho foi realizar uma comparação de coordenadas geográficas em imagem e mapa do rio Madeira, em Porto Velho. Usaram também um mapa cartográfico da mesma região, executado pelo DSG do Brasil em 1977, com escala 1:50000, projeção UTM. A banda 5 foi registrada no mapa, utilizando 5 pontos de controle e ajustando um polinômio de grau um. Os resíduos para cada ponto foram próximos de zero, o que indica que os resultados podem ser considerados satisfatórios.

Utilizando oito imagens LANDSAT TM-5 em diferentes épocas, de fevereiro de 1985 a fevereiro de 1992, ZAINAL, DALBY e ROBINSON (1993)

estudaram as mudanças ecológicas na costa leste de Bahrain. Todas as imagens foram registradas numa carta náutica com escala 1:25000, usando uma polinomial de segunda ordem. A técnica de reamostragem utilizada foi a do vizinho mais próximo. O erro médio foi menor do que um pixel, baseado em 11 pontos de controle.

TREITZ, HOWARTH e GONG (1992) realizaram um estudo da franja rural-urbana na cidade de Toronto, Canadá. Para tanto, utilizaram imagens SPOT multiespectral e pancromática, de 18 de agosto de 1989 da área de Markham (cena K615/J262). Primeiramente, os dados da imagem pancromática foram reamostrados para 20 m e registrados com a multiespectral, usando uma polinomial de primeira ordem, com 10 pontos de controle. Os erros residuais foram de 4,6 m tanto na direção x como y, o que foi considerado bom, quando comparado com a resolução espacial dos conjuntos de dados das imagens.

Na quantificação da clorofila "a" em águas costeiras, EKSTRAND (1991) utilizou duas imagens LANDSAT TM, datadas de 10/05/1988 e 07/05/1990. A área de estudo foi a baía de Himmerfjärden, ao sul de Estocolmo, Suécia. As imagens foram submetidas a correção atmosférica, usando pixels de águas claras para determinar a radiância adicional na banda 4. Foi estimada uma reta de regressão entre a banda 4 e as bandas 1 e 3, para obter uma estimativa da radiância causada pelo espalhamento atmosférico. Esse procedimento, segundo o autor, foi satisfatório para calibrar os valores da radiância nas imagens usadas no estudo.

Na determinação da linha de águas na costa brasileira, ALMEIDA (1991) utilizou imagens LANDSAT TM-5 de 20/06/84, 13/08/86 e 02/08/88, da baía de São Marcos, Estado do Maranhão. Essas imagens foram registradas numa carta náutica com escala 1:135000, usando 9 pontos de controle. Foi feito o ajuste de uma polinomial de grau um, utilizando o método dos mínimos quadrados. A precisão do registro foi calculada pela aplicação do método dos erros quadráticos médios, sendo de 29.2 m, menos que um pixel, considerada suficiente para o trabalho em questão.

Analisando o desfolhamento em Michigan, JORIA, AHEARN e CONNOR (1991) realizaram uma comparação entre os produtos obtidos dos satélites SPOT e LANDSAT. Usaram uma imagem SPOT de 27 de junho de 1988

e uma LANDSAT TM-5 de 29 de junho de 1988. As imagens foram registradas, usando o método de reamostragem do vizinho mais próximo, com um erro de menos de um pixel.

LEE, SHIMABUKURO e HERNANDEZ FILHO (1990) utilizaram imagens LANDSAT TM-5 de quatro diferentes épocas (19/05/84, 25/03/87, 20/11/87 e 15/04/89), para realizar o monitoramento de áreas reflorestadas, no município de Mogi-Guaçu, Estado de São Paulo, cobrindo uma área aproximada de 236 quilômetros quadrados. As imagens de 1984 e 1989 foram utilizadas para a detecção de mudanças ocorridas nas áreas reflorestadas, enquanto as imagens de março e novembro de 1987 foram utilizadas com o objetivo de observar a variabilidade das componentes principais devido às características sazonais da cobertura do solo. O pré-processamento dos dados incluiu o registro geométrico dos pares de imagens de 1984 e 1989, e das imagens de março e novembro de 1987. As imagens de abril de 1989 e novembro de 1987 serviram como imagens de referência. Foram usados 24 e 26 pontos de controle, respectivamente, e os resultados obtidos foram considerados muito bons.

BRUM (1989) realizou a integração de canais multiespectrais e pancromáticos de sensor HRV (SPOT) para obtenção de composições coloridas com resolução espacial próxima a 10 m. Para tanto, utilizou uma imagem pancromática de 4 de abril de 1986, e uma imagem multiespectral de 12 de maio de 1987, ambas abrangidas pela órbita ponto WRS 716-397. Essas imagens foram registradas, utilizando 11 pontos de controle e o ajuste de um polinômio do segundo grau, sendo os resultados considerados satisfatórios.

Vários outros trabalhos têm utilizado técnicas de pré-processamento. Entre eles, pode-se citar FIGUEIRA et al (1993), SILVA (1993), BIERWIRTH, LEE e BURNE (1993), HELDER, QUIRK e HOOD (1992), DUGUAY e LEDREW (1992), CARRARA, FORESTI e SANTOS (1991), EERENS, CALMON, SAPION, DEVOS E GOMBEER (1991).

4.4 Técnicas de Realce

As técnicas de realce de imagens constituem-se em transformações sobre os níveis de cinza da imagem visando melhorar a sua qualidade. Essas imagens podem posteriormente ser interpretadas pelo analista ou podem integrar um conjunto de canais, formando uma composição colorida para ser utilizada em um processo de classificação.

A princípio, não se pode afirmar qual a melhor técnica a ser utilizada, haja visto que os resultados obtidos do realçamento são avaliados pelo analista, tomando esse julgamento muito subjetivo. Existe uma grande variedade de técnicas de realce, podendo-se distinguir dois tipos gerais: transformações pontuais e transformações locais.

As transformações pontuais modificam o valor do nível de cinza de cada pixel, dependendo, unicamente, do seu nível de cinza e do tipo de transformação utilizada, enquanto que as transformações locais modificam o valor do nível de cinza de cada pixel, levando em consideração o contexto dos níveis de cinza dos pixels vizinhos.

Em função dos tipos de transformações, as técnicas de realce podem ser divididas em radiométricas, espaciais e espectrais. O realce radiométrico ou de contraste é aquele onde se muda apenas o valor do nível de cinza do pixel, como resultado da aplicação de um tipo de transformação. Quando se muda o valor do nível de cinza do pixel em função da sua relação com seus vizinhos, trata-se do realce espacial. O realce é espectral quando o valor do nível de cinza do pixel é comparado entre os diferentes canais dos sistemas sensores dos satélites.

Nas seções subseqüentes, serão apresentadas algumas das técnicas de realce mais utilizadas.

4.4.1 Manipulação de Contraste

A técnica de manipulação de contraste expande os valores dos níveis de cinza da imagem de entrada de modo que o novo histograma da imagem possua a forma desejada. Com a redistribuição dos valores dos níveis de cinza, a qualidade da imagem é melhorada, com isso obtendo-se melhor visualização das informações nela contidas. Essas informações, muitas vezes, ficam restritas a uma estreita faixa do intervalo possível, que vai de 0 a 255. O aumento do contraste na imagem é dado pela modificação dessa distribuição.

Para a sua implementação é usado:

$$NC_{\text{nov}}(i,j) = \frac{NC(i,j) - NC_{\text{min}}}{NC_{\text{max}} - NC_{\text{min}}} (NC_{R_{\text{max}}} - NC_{R_{\text{min}}}) + NC_{R_{\text{min}}} \quad (4.5)$$

Onde: $NC_{\text{nov}}(i,j)$ = nível de cinza da nova banda

$NC(i,j)$ = nível de cinza da banda original

NC_{min} = nível de cinza mínimo da banda original

NC_{max} = nível de cinza máximo da banda original

$NC_{R_{\text{min}}}$ = nível de cinza mínimo da nova banda

$NC_{R_{\text{max}}}$ = nível de cinza máximo da nova banda

Essa técnica é uma transformação linear radiométrica e pontual na imagem.

Quando o histograma da imagem não se apresenta simétrico, torna-se inviável o controle simultâneo dos níveis de cinza e da saturação utilizando-se a transformação acima citada. Então, pode-se usar a transformação linear por partes, sendo que essa transformação ajusta diferentes segmentos de reta em diferentes partes do histograma.

Com o uso da transformação linear por partes, pode-se modificar a forma do histograma, reduzindo a assimetria, o que melhora consideravelmente o contraste. Para a sua implementação, faz-se:

$$NC_{\text{novo}}(i,j) = \frac{NC(i,j) - L_{\text{orig}}(m)}{L_{\text{orig}}(m+1) - L_{\text{orig}}(m)} (L_{\text{novo}}(m+1) - L_{\text{novo}}(m)) + L_{\text{novo}}(m) \quad (4.6)$$

Dado que: $L_{\text{orig}}(m) \leq NC(i,j) \leq L_{\text{orig}}(m+1)$

Onde: $NC_{\text{novo}}(i,j)$ = nível de cinza da nova banda

$NC(i,j)$ = nível de cinza da banda original

L_{orig} = limite do segmento na banda original

L_{novo} = limite do segmento na nova banda

4.4.2 Filtragem Espacial

Na filtragem espacial, a transformação leva em consideração os valores dos níveis de cinza da vizinhança de cada pixel.

Uma característica das imagens que deve ser considerada, nesse tipo de transformação, é o parâmetro freqüência espacial, que é definido como o número de mudanças dos valores de níveis de cinza por unidade de distância de uma parte particular de uma imagem (JENSEN, 1986). Se, em uma determinada área, existem poucas mudanças dos valores dos níveis de cinza, é dito ser uma área de "baixa freqüência", enquanto que, se existem muitas mudanças, é referida como uma área de "alta freqüência".

Para diminuir as componentes de baixa freqüência espacial e ressaltar as altas freqüências, devem ser usados filtros de alta freqüência, também chamados de filtros passa alta. Na utilização desses filtros, obtém-se um realçamento das linhas e contornos. Isso apresenta o inconveniente de realçar, também, os ruídos existentes na imagem (QUINTANILHA, 1990).

Para diminuir as componentes de alta freqüência espacial e realçar as baixas freqüências, devem ser usados filtros de baixa freqüência ou filtros passa baixa. Quando esses filtros são aplicados, obtém-se o realçamento dos padrões representantes das estruturas dentro da imagem, dessa forma suavizando as variações mais bruscas e atenuando a influência de ruídos presentes na imagem.

Para a implementação e aplicação desses tipos de filtros, utiliza-se uma matriz quadrada ($m \times m$), com m podendo assumir valor maior ou igual a três, sendo essa matriz centrada em cada um dos pixels da imagem e envolvendo os seus vizinhos. Dessa forma, resulta um novo valor para cada pixel, que é a média ponderada dos valores dos seus vizinhos. A matriz percorre, então, toda a imagem. Os novos valores dos níveis de cinza dos pixels são calculados através da seguinte expressão:

$$NC_{\text{novo}}(i,j) = \frac{\sum_{k=1}^m \sum_{l=1}^m NC(k,l) \cdot p(k,l)}{\sum_{k=1}^m \sum_{l=1}^m p(k,l)} \quad (4.7)$$

Onde: $NC_{\text{novo}}(i,j)$ = novo valor do nível de cinza do pixel da posição i, j

$NC(k,l)$ = valor do nível de cinza na banda original, do pixel da posição (k,l) da máscara

$p(k,l)$ = peso do pixel da posição (k,l) da máscara

A filtragem espacial é uma transformação local e espacial.

4.4.3 Transformação IHS

Para a visualização de imagens digitais é utilizado um sistema de composição colorida, com as cores vermelho (R), verde (G) e azul (B), sistema RGB, sendo que cada pixel é representado por um vetor que contém os níveis de cinza correspondentes a cada cor.

A transformação IHS (Intensidade, Matiz e Saturação) descreve as sensações subjetivas de brilho, cor e saturação para cada cor do sistema RGB.

Essa transformação tem como objetivo o realçamento de imagens, através das transformações dos canais originais RGB nos canais IHS, e vice versa.

Para a implementação dessa transformação, devem-se seguir os seguintes passos:

- Calcular a Intensidade

$$I = R + G + B \quad (4.8)$$

Onde: I = intensidade

- Verificar qual o canal que apresenta menor intensidade:

- Se a intensidade no azul for menor:

$$H = \frac{(G-B)}{(I-3B)} \quad (4.9)$$

$$S = \frac{(I-3B)}{I} \quad (4.10)$$

- Se a intensidade no vermelho for menor:

$$H = 1 + \frac{(B-R)}{(I-3R)} \quad (4.11)$$

$$S = \frac{(I-3R)}{I} \quad (4.12)$$

- Se a intensidade no verde for menor

$$H = 2 + \frac{(R-G)}{(I-3G)} \quad (4.13)$$

$$S = \frac{(I-3G)}{I} \quad (4.14)$$

A seguir, devem-se criar três bandas, R, G e B, cujos valores irão depender do valor de H, da seguinte forma:

- Se $0 \leq H \leq 1$

$$R = \frac{I}{3}(1+2S+SH) \quad (4.15)$$

$$G = B + IHS \quad (4.16)$$

$$B = \frac{1}{3} (1-S) \quad (4.17)$$

- Se $1 < H \leq 2$

$$R = \frac{1}{3}(1-S) \quad (4.18)$$

$$G = \frac{1}{3} [1+2S-3S(H-1)] \quad (4.19)$$

$$B = \frac{1}{3} [1-S+3S(H-1)] \quad (4.20)$$

- Se $2 < H \leq 3$

$$R = \frac{1}{3}[1-S+3S(H-2)] \quad (4.21)$$

$$G = \frac{1}{3}(1-S) \quad (4.22)$$

$$B = \frac{1}{3}[1+2S-3S(H-2)] \quad (4.23)$$

Esse tipo de transformação é pontual e espectral.

4.4.4 Transformação por Componentes Principais

As imagens digitais multiespectrais apresentam uma correlação, normalmente alta, entre as diferentes bandas de uma mesma cena. Essa correlação indica que existem informações redundantes, sendo que essas, além de ocasionarem dificuldades na interpretação, também aumentam o custo computacional e operacional.

Para solucionar esse problema, pode-se usar a técnica de componentes principais. Tal transformação elimina a redundância existente entre as várias bandas, através de uma combinação linear. Assim, as novas bandas geradas não são correlacionadas entre si.

Inicialmente, toma-se a matriz de variância-covariância (VC) entre as imagens. Essa matriz é simétrica e sua dimensão é igual ao número de bandas utilizadas. Os elementos da diagonal principal são as variâncias de cada banda, e os demais elementos contêm as covariâncias entre as bandas.

$$VC = \begin{bmatrix} \text{var}(C_1) & \text{Cov}(C_1, C_2) & \dots & \text{Cov}(C_1, C_n) \\ \text{Cov}(C_2, C_1) & \text{Var}(C_2) & \dots & \text{Cov}(C_2, C_n) \\ \cdot & \cdot & \ddots & \cdot \\ \text{Cov}(C_n, C_1) & \text{Cov}(C_n, C_2) & \dots & \text{Var}(C_n) \end{bmatrix} \quad (4.24)$$

Nesse caso, a solução é aquela que permite que VC possa ser reduzida a uma matriz diagonal D. Isso é obtido pela pré multiplicação e pós multiplicação de VC, por uma matriz ortonormal O, de tal forma que:

$$O' VC O = D \quad (4.25)$$

Os elementos da diagonal da matriz D são os autovalores da matriz VC, e as colunas da matriz O são os autovetores da matriz VC.

Os autovalores são obtidos a partir da resolução do sistema:

$$|VC - DI| = 0, \text{ onde } I \text{ é a matriz identidade.}$$

Os autovetores são obtidos através das equações:

$$(VC - d_i I)t_i = 0 \quad (4.26)$$

$$o_i = \frac{t_i}{(t_i' t_i)}, \quad i = 1, \dots, d \quad (4.27)$$

Onde os t_i 's são determinados de tal forma que:

$$o_i' \cdot o_i = 1; \quad o_i' \cdot o_j = 0, \quad i \neq j \quad (4.28)$$

As novas bandas associadas a cada uma das componentes principais têm variâncias ordenadas, isto é, a variação da primeira componente

principal é maior que as demais, a segunda maior do que as outras e assim por diante.

Isso permite que se faça a escolha do número de componentes principais (normalmente menor do que o número de bandas iniciais), mantendo-se o máximo de informação existente, ou seja, reduz-se a dimensionalidade dos dados, com uma perda mínima de informação.

4.4.5 Divisão entre Canais

Esta técnica de realce consiste em efetuar-se a divisão dos valores dos níveis de cinza de cada pixel de uma determinada banda pelo respectivo valor do nível de cinza de outra banda, gerando uma nova banda.

$$NC_{\text{nov}} = \frac{NC_1}{NC_2} \quad (4.29)$$

Onde: NC_{nov} = valor do nível de cinza da nova banda

NC_1 e NC_2 = valores dos níveis de cinza das bandas envolvidas

De acordo com QUINTANILHA (1990), as principais vantagens da técnica de divisão entre canais são:

- a atenuação dos efeitos atmosféricos e topográficos, pois se supõe que ambos influenciam igualmente os dois canais;
- a diferenciação de alvos dentro das cenas com valores de níveis de cinza não proporcionais;
- a redução da dimensionalidade dos dados, uma vez que as informações mais importantes de dois canais estarão representadas em uma mesma imagem.

Para o mesmo autor, as desvantagens encontradas são a perda de informação sobre os efeitos do relevo e a não distinção dos alvos contidos nas cenas com níveis de cinza proporcionais ou muito próximos.

4.4.6 Aplicações de Técnicas de Realce

JACOBS, MAXIMIANO E IHLENFELD (1993) utilizaram a técnica de manipulação de contraste para realçar a composição colorida (Bandas 3, 4 e 5 do sensor TM, LANDSAT 5) com o propósito de classificar a imagem para identificar o uso atual do solo. Concluíram que a técnica de realce utilizada melhorou a qualidade da imagem, apresentando as classes temáticas bem definidas.

No trabalho desenvolvido por FRANZONI (1993), foi utilizada a técnica de manipulação de contraste nas bandas 3, 4 e 5 do sensor TM (LANDSAT 5), com o objetivo de realçar os elementos contidos nas imagens. A transformação linear aplicada permitiu a distribuição eqüidistante dos níveis de cinza de 0 a 255, resultando num maior contraste entre as várias classes de uso do solo e, desse modo, sua melhor identificação.

ALVES, LAPOLLI, FRANZONI e LUZ (1993) no trabalho intitulado "Integração de Imagens Multiespectral e Pancromática SPOT visando ao Estudo de Áreas Urbanas" comprovaram a real efetividade do uso da técnica de transformação IHS, onde a análise visual das imagens realçadas mostrou que as informações, principalmente referentes às áreas urbanas, encontravam-se bem mais delineadas quando comparadas às imagens originais.

Com o objetivo de realçar as imagens visando melhorar os padrões de áreas urbanas, LAPOLLI, ALVES, LUZ e ZARDO (1993) testaram diversos filtros em uma imagem SPOT multiespectral, abrangendo parte do município de Joinville, localizado no Estado de Santa Catarina. Concluíram que a utilização de filtragem espacial, com "máscara" apropriada, proporciona o realce das imagens, melhorando significativamente o seu aspecto visual para a análise das características e padrões de áreas urbanas.

AHEARN e WEE (1991) examinaram o volume do espaço de dados de imagens SPOT - XS e LANDSAT - TM (seis bandas, excluindo a banda termal), utilizando análise de componentes principais. Comparações foram feitas para a mesma área geográfica. Como resultado das comparações, foi verificado que o volume do espaço de dados das bandas 2,3 e 4 do LANDSAT - TM, que é espectralmente similar às bandas 1,2 e 3 do SPOT - XS, foi 70 a 100% maior do que os volumes das imagens SPOT - XS analisadas, sendo que isso pode ser resultante da maior precisão radiométrica do sensor LANDSAT - TM para essas bandas espectrais. As bandas 3,4 e 5 do LANDSAT- TM, no vermelho, infravermelho próximo e infravermelho médio, respectivamente, são provavelmente as menos correlacionadas das seis bandas TM analisadas e apresentam, aproximadamente, uma ordem de grandeza maior do que os volumes dos dados do SPOT-XS. Posteriormente, a análise do volume do espaço de dados foi utilizada para otimizar o processo de classificação por máxima verossimilhança, através da redução do tempo computacional necessário no processo, bem como da memória requerida.

No trabalho desenvolvido por KURKDJIAN (1990), foi usada a técnica de transformação IHS, devido ao fato de que, nos estudos da estruturação do espaço intra-urbano, através de dados de sensoriamento remoto orbital, tem-se deparado com problemas relativos às resoluções espacial e espectral desses produtos. Foram, então, gerados produtos híbridos, pela integração da composição TM 4,3,2 com dados SPOT-PAN; da composição SPOT-XS com dados SPOT-PAN e da composição SPOT-XS com aerofoto pancromática. A técnica IHS, em todos os casos, mostrou-se eficiente para as integrações acima citadas, pois permite preservar a resolução espacial do produto de resolução mais fina, acrescentando-lhe as qualidades espectrais do outro produto. As imagens resultantes permitiram uma separação mais detalhada dos alvos urbanos que aquela oferecida pelos produtos básicos que as compuseram.

LEE, SHIMABUKURO e HERNANDES FILHO (1990) realizaram o monitoramento de áreas reflorestadas e utilizaram a técnica de componentes principais, observando que existe uma diferença significativa na contribuição das bandas para a formação da primeira componente, a partir da comparação de dados não padronizados e dados padronizados. Concluíram que, embora essa seja uma técnica poderosa de redução de dados, ela deve ser usada somente

com um bom conhecimento das características da área de estudo, para evitar conclusões errôneas.

CARPER, LILLESAND e KIEFER (1990) utilizaram a transformação IHS para fundir dados de imagens multiespectral e pancromática obtidas com o sensor HRV (SPOT), com o objetivo de criar uma composição de interpretabilidade realçada. Concluíram que o uso de dados de correlação de uma imagem, embora não seja uma medida absoluta da qualidade da imagem de saída, proporciona uma indicação da quantidade de mudança visual nos dados, após o processamento. A inspeção da correlação da intensidade a partir dos dados originais com a intensidade dos dados simulados, bem como as correlações entre as imagens multiespectrais originais e aquelas geradas pelos dados fundidos, podem ser usados para avaliar quão preciso é o conteúdo espectral dos dados simulados em relação aos dados das imagens multiespectrais originais.

O realçamento de imagens LANDSAT TM foi realizado por WALSH, COOPER, ESSEN, e GALLAGER (1990) para propiciar uma melhor caracterização dos aspectos hidrológicos, tais como: corpos de água, rios e geleiras, na região de Montana. As técnicas de realce utilizadas foram: razão entre canais, análise de componentes principais e filtragem espacial. Na razão entre canais, várias combinações foram realizadas. As combinações entre canais TM4/TM2 e TM4/TM3 realçaram a localização de características hidrológicas (rios, lagos e açudes). Entretanto, geleiras não foram bem delineadas. A razão TM4/TM1 mostrou mais estruturas topográficas do que as razões TM4/TM3 e TM4/TM2. Quando combinadas as bandas TM5/TM3, houve realçamento de geleiras e de sedimentos dentro de corpos de água, bem como o delineamento dos rios dominantes. Por outro lado, as estruturas geológicas foram suprimidas. As razões TM5/TM2, TM5/TM1 e TM7/TM1 apresentaram uma boa interface entre terra e água, salientando todas as características hidrológicas avaliadas.

A análise de componentes principais mostrou que 98,6% da variância total das seis bandas TM foi explicado pelas três primeiras componentes principais. A primeira componente permitiu um realçamento da topografia, solo exposto, faces de rochas e corpos de água. Lagos e sombras não foram bem discriminados por essa componente, principalmente em áreas de contraste estrutural alto. Geleiras não foram claramente distinguidas e rios de baixa ordem e rios intermitentes foram pouco representados. A segunda

componente principal suprimiu as sombras e proporcionou somente uma moderada representação da vegetação. Neve e geleiras foram muito bem realçadas através de seus limites e por meio de suas áreas extensas. Pela representação pobre da sombra, vegetação e estrutura geológica, tornou-se difícil o reconhecimento de rios de baixa ordem e rios intermitentes. A discriminação de vegetação e a interface entre terra e água ficou bem realçada na terceira componente principal; entretanto, geleiras não foram bem delineadas. Na última técnica de realce, a filtragem espacial, seis filtros, com máscaras diferentes, foram aplicados. Dessas, três realçaram os rios, um deles foi perturbado por um ruído que permaneceu na imagem, enquanto os outros dois destacaram os grandes rios e os rios em áreas de alto relevo. Verificou-se, portanto, que as técnicas de realce empregadas permitiram uma avaliação das características hidrológicas da região estudada. Além disso, dentre os objetivos do trabalho, buscava-se mostrar que o uso de imagens realçadas, juntamente com dados auxiliares de modelos numéricos de terreno (MNT), integrados em um sistema de informações geográficas (SIG), aumentaram o poder de interpretação das análises e permitiram uma completa validação das interpretações realizadas. Para essa validação, as próprias técnicas de realce utilizadas serviram como dados de controle. Esse objetivo também foi alcançado, pois os realces digitais mostraram-se melhores avaliadores do que quando utilizados somente dados de sensoriamento remoto ou dados de SIG.

Muitas outras publicações testemunham a aplicabilidade das técnicas de realce. Entre elas, cita-se: MAZZOCATO, TORRUSIO e MAKOWIECKI (1993); AMARO, SÁ VAUCHEZ e DUARTE (1993); MARTINS, MATTOS e BRANDINI (1993); SHETTIGARA (1992); VIEIRA e KURKDJIAN (1991); CHAVEZ, SIDES e ANDERSON (1991); HARRIS, MURRAY e HIROSE (1990); BRUM (1989); FORESTI, FLORENZANO, ERTHAL e GODOY JÚNIOR (1989); CLICHE, BONN e TEILLET (1985); HAACK(1984).

4.5 Técnicas de Classificação de Imagens Digitais

A análise dos dados da superfície terrestre obtidos por sensoriamento remoto permite a extração das informações temáticas úteis, sendo que a classificação multiespectral é um dos métodos mais freqüentemente

utilizados para essa extração. Nesse método, as imagens de uma área são coletadas em diversas regiões do espectro eletromagnético e seus pixels apresentam-se coincidentes (FIGURA 4.1).

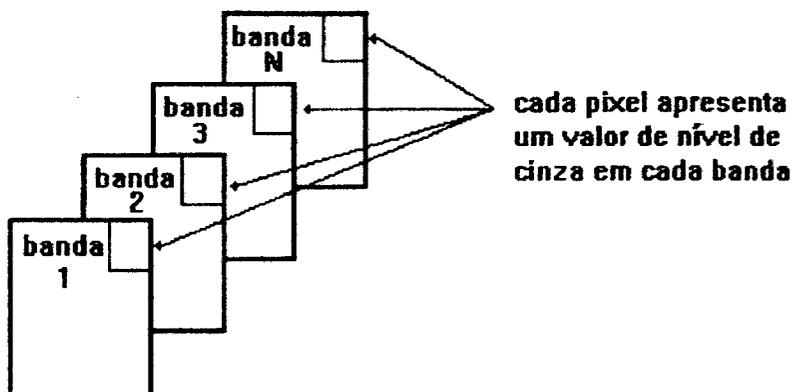


FIGURA 4.1: Conjunto de Bandas de uma Imagem obtida por Sensoriamento Remoto

Fonte: Adaptada de RICHARDS, 1986

Podem ser distinguidas três fases sucessivas no processo de classificação digital. Na primeira fase, são geradas as estatísticas usadas para identificar as diversas classes. A segunda fase envolve a atribuição de pixels a uma das classes. A última fase apresenta os resultados.

A fase de atribuição tem ocupado o centro de atenção dos especialistas. Estratégias diferentes foram desenvolvidas para melhorar o desempenho dos classificadores, pela introdução de novos algoritmos ou pela incorporação de informações adicionais (CHUVIECO e CONGALTON, 1988).

A classificação de imagem multiespectral consiste em atribuir cada pixel da imagem a uma das possíveis classes, através de uma regra de decisão, sendo cada um dos pixels representado por um vetor (4.30), cujos elementos correspondem aos valores dos níveis de cinza de cada banda.

$$x = \begin{bmatrix} x_1 \\ x_2 \\ \cdot \\ \cdot \\ x_N \end{bmatrix} \quad (4.30)$$

As classes podem ser previamente determinadas, o que se denomina classificação supervisionada, ou podem ser determinadas a partir do próprio conjunto de dados, o que se chama de classificação não supervisionada.

4.5.1 Métodos de Classificação Supervisionados

Classificação Supervisionada é o procedimento mais freqüentemente utilizado para análise quantitativa de dados de imagem de sensoriamento remoto (RICHARDS, 1986). Baseia-se no uso de algoritmos para atribuir os pixels, de uma imagem, como representantes de tipos de cobertura da terra ou classes.

Conforme JENSEN (1986), para obtenção de uma classificação supervisionada, de dados de sensoriamento remoto, de alta precisão e confiabilidade, é importante considerar os seguintes aspectos:

- um esquema de classificação apropriado precisa ser adotado, ou seja, necessita-se decidir o conjunto de tipos de cobertura da terra em que a imagem deve ser segmentada. Essas são as classes de informação. Poderiam ser, por exemplo, água, vegetação, etc.;
- áreas de treinamento representativas devem ser selecionadas;
- estatísticas devem ser extraídas a partir de dados espectrais das áreas de treinamento;
- as estatísticas devem ser analisadas para selecionar as bandas apropriadas para serem usadas no processo de classificação. Isso pode envolver computação gráfica e/ou métodos estatísticos para avaliar o grau de separabilidade entre classes;
- deve ser selecionado um algoritmo de classificação apropriado;
- a imagem deve ser classificada em "m" classes;

- a precisão da classificação deve ser avaliada estatisticamente.

No método de classificação supervisionado, a identificação e localização de algumas classes de uso do solo, tais como área urbana, florestas, etc., são conhecidas a priori, por meio de trabalho de campo, análise de fotografias aéreas, mapas e experiência pessoal. A análise tenta identificar locais específicos nos dados de sensoriamento remoto que representam exemplos homogêneos dessas classes conhecidas. Essas áreas são comumente referenciadas como áreas de treinamento, porque suas características espectrais são usadas para treinar o algoritmo classificador.

Na seleção de áreas de treinamento, pode ocorrer que algumas classes consideradas de interesse, como, por exemplo, a classe de áreas urbanas, não apresentem um comportamento espectral homogêneo em toda a sua extensão espacial. As técnicas de processamento digital para classificação dos tipos de uso do solo urbano enfrentam o problema de que a variância interna das classes é muito grande, em função da diversidade de objetos encontrados nas diferentes classes. Essa situação pode ser exemplificada na análise de áreas residenciais e áreas comerciais. As áreas residenciais apresentam-se compostas por diversos objetos, como concreto, asfalto, e vegetação, sendo esses objetos distribuídos numa determinada proporção, enquanto, nas áreas comerciais, encontram-se os mesmos objetos, mas com uma distribuição diferente.

Além disso, duas classes distintas podem apresentar comportamento espectral semelhante, provocando erros de classificação devido à superposição que essas classes apresentam no espaço de atributos.

Para uma avaliação da homogeneidade das áreas de treinamento, pode-se verificar os seus histogramas. Uma área homogênea apresentará um histograma unimodal, enquanto uma área heterogênea terá um histograma multimodal. Nesse caso, para melhorar o desempenho da classificação, deve-se transformar o histograma em unimodal, retirando os pixels que não pertencem à classe de interesse (NOVO, 1989).

Quando se aplicam técnicas estatísticas de classificação, deve-se ter o número de pixels das áreas de treinamento grande o bastante, para permitir a estimativa das características espectrais da classe de interesse. Todos os pixels, tanto dentro como fora dessas áreas de treinamento, são então avaliados

e atribuídos à classe cuja probabilidade de eles pertencerem seja maior. Esse método é subjetivo, dado que o analista tenta classificar categorias de informação que são muitas vezes compostas de classes espectrais diferentes.

Vários são os métodos de classificação supervisionados que podem ser usados para atribuir um pixel a uma classe específica. Para escolher qual o classificador a ser utilizado, deve-se analisar a natureza do dado de entrada e a saída desejada. Os algoritmos de classificação paramétricos partem da suposição que os vetores de medida observados de cada classe em cada banda, durante a fase de treinamento, são normalmente distribuídos. Os algoritmos de classificação não paramétricos não fazem suposições sobre a forma de distribuição dos dados, exceto que o grupo de dados pode ser separado por alguma função discriminante. Entre os algoritmos de classificação supervisionados mais usados, pode-se citar o da máxima verossimilhança, o do paralelepípedo e o da distância mínima.

A classificação usando o algoritmo de máxima verossimilhança é o método de classificação supervisionado mais comumente usado com dados de sensoriamento remoto. Esse algoritmo parte do pressuposto que os níveis de cinza de cada classe seguem uma distribuição normal multivariada.

Supondo que as classes espectrais para uma imagem são representadas por c_i , $i = 1, 2, \dots, m$, onde m é o número total de classes, $p(c_i / x)$ representa a probabilidade que o pixel pertença à classe c_i , dado o valor observado x . A classificação é realizada, atribuindo x à classe c_i , se

$$p(c_i / x) > p(c_j / x) \text{ para todo } i \neq j \quad (4.31)$$

Considerando a definição de probabilidade condicional:

$$p(c_i / x) = \frac{p(x, c_i)}{p(x)} = \frac{p(x / c_i)p(c_i)}{p(x)} \quad (4.32)$$

Onde: $p(x / c_i)$ = probabilidade de encontrar o pixel x , dado que se está na classe c_i

$p(c_i)$ = probabilidade que a classe c_i ocorra na imagem (definida como probabilidade a priori)

$p(x)$ = probabilidade de encontrar um pixel de qualquer classe na posição x

A regra de decisão torna-se:

$$x \in c_i \text{ se } \frac{p(x/c_i)p(c_i)}{p(x)} > \frac{p(x/c_j)p(c_j)}{p(x)} \text{ para todo } i \neq j \quad (4.33)$$

Como $p(x)$ é comum para todas as classes, tem-se:

$$x \in c_i \text{ se } p(x/c_i)p(c_i) > p(x/c_j)p(c_j) \text{ para todo } i \neq j \quad (4.34)$$

Os valores de $p(x/c_i)$ podem ser conhecidos através dos dados de treinamento e admite-se que $p(c_i)$ seja também conhecido ou possa ser estimado a partir do conhecimento do analista.

A regra de decisão pode ser sumarizada da seguinte forma: atribuir o pixel a classe para a qual o valor de $p(x/c_i)p(c_i)$ seja máximo. Como maximizar esse valor equivale a maximizar seu logaritmo, a função discriminante para o método da máxima verossimilhança, $f_i(x)$ resulta em:

$$\begin{aligned} f_i(x) &= \ln\{p(x/c_i)p(c_i)\} \\ &= \ln p(x/c_i) + \ln p(c_i) \end{aligned} \quad (4.35)$$

A regra de decisão é dada por:

$$x \in c_i, \text{ se } f_i(x) > f_j(x) \text{ para todo } i \neq j \quad (4.36)$$

Assumindo que as classes seguem o modelo normal multivariado, e considerando que estão sendo utilizadas N bandas, o valor da função de probabilidade $p(x/c_i)$ será dado por:

$$p(x/c_i) = (2\pi)^{-N/2} |\Sigma_i|^{-1/2} \exp\left\{-\frac{1}{2}(x-m_i)^t \Sigma_i^{-1}(x-m_i)\right\} \quad (4.37)$$

Onde: m_i = vetor de médias dos dados da classe c_i

Σ_i = matriz de covariâncias dos dados da classe c_i

$|\Sigma_i|$ = determinante da matriz de covariância Σ_i

A função discriminante para o classificador de máxima verossimilhança será então:

$$f_i(x) = \ln \left\{ (2\pi)^{-N/2} |\Sigma_i|^{-1/2} \exp \left\{ -\frac{1}{2} (x - m_i)^t \Sigma_i^{-1} (x - m_i) \right\} \right\} + \ln p(c_i) \quad (4.38)$$

$$f_i(x) = -\frac{N}{2} \ln (2\pi) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (x - m_i)^t \Sigma_i^{-1} (x - m_i) + \ln p(c_i)$$

Como o termo $-\frac{N}{2} \ln (2\pi)$ é constante para todas as classes, tem-se:

$$f_i(x) = -\frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (x - m_i)^t \Sigma_i^{-1} (x - m_i) + \ln p(c_i) \quad (4.39)$$

Normalmente se considera que $p(c_i)$ representa uma distribuição uniforme (probabilidades a priori iguais), e a função discriminante torna-se:

$$f_i(x) = -\frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (x - m_i)^t \Sigma_i^{-1} (x - m_i) \quad (4.40)$$

No algoritmo do paralelepípedo utilizado na classificação, nos dados de treinamento, para cada classe "c" e cada banda "k" é calculado o valor médio " m_{ck} " e o desvio padrão " s_{ck} ", com base nos valores dos níveis de cinza de cada banda. Tomando como limiar um desvio padrão, o algoritmo decide que o pixel "x" pertence à classe "c" se, para todas as bandas, o nível de cinza de "x" está compreendido entre $m_{ck} - s_{ck}$ e $m_{ck} + s_{ck}$. Os limites de decisão formam um paralelepípedo n - dimensional no espaço característico. Quando um pixel não se encontra dentro dos limites estabelecidos, é atribuído a uma categoria não classificada.

O algoritmo do paralelepípedo é um método computacionalmente eficiente para classificar dados de sensoriamento remoto. Infelizmente, como pode haver sobreposição de alguns paralelepípedos, é possível que um pixel satisfaça os critérios para mais de uma classe. Nesse caso, ou ele é atribuído à primeira classe, ou é atribuído à classe em que satisfaz critérios de mínima distância em relação às médias daquelas classes.

Como o algoritmo do paralelepípedo, o algoritmo de distância mínima às médias das classes necessita, para cada classe, de um vetor de médias, correspondendo às diversas bandas. Para cada pixel, é calculada a distância euclidiana às médias de cada classe. O pixel é, então, atribuído à classe de cuja média ele apresenta distância mínima. Para evitar que pixels muito afastados da média da classe sejam nela classificados, é necessário que o analista estabeleça um limiar, além do qual o pixel não será atribuído àquela classe, mesmo que esteja mais próximo da média dessa categoria. Nesse caso, o pixel é atribuído a uma categoria não classificada.

4.5.2 Métodos de Classificação não Supervisionados

Nos métodos de classificação não supervisionados, as identidades dos padrões a serem especificados como classes dentro de um cenário não são, geralmente, conhecidas a priori. Isso porque as características da superfície do cenário não são bem definidas ou a área em questão é desconhecida. Nesse caso, os pixels devem ser agrupados em classes espectrais diferentes, de acordo com algum critério estatisticamente determinado. Torna-se responsabilidade do analista rotular esses grupos (JENSEN, 1986).

Nestes métodos de classificação, a seleção do classificador ou da regra de decisão depende da natureza dos dados de entrada e das saídas que se deseje. Entre os algoritmos de classificação não supervisionados mais utilizados, destacam-se os algoritmos das k-médias e do líder.

O algoritmo das k-médias, baseia-se no valor da distância euclidiana entre os pixels. Inicialmente, é feita uma partição, com os pixels sendo distribuídos em k grupos, e é calculada a distância entre cada pixel e a média de cada grupo. Em seguida, é computado o erro, ou seja, o somatório dos quadrados das distâncias entre cada elemento e a média de seu grupo. Procura-se, então, minimizar o erro, mudando os pixels de grupo e computando as novas médias de grupo com as respectivas distâncias. A busca termina quando não se pode mais diminuir o erro pela movimentação dos pixels entre os grupos (HARTIGAN, 1975). Esse algoritmo é considerado de execução relativamente

rápida, mas depende da partição inicial. A escolha de uma partição inicial diferente pode conduzir a uma partição final menor.

O algoritmo do líder, para classificação de imagem, constrói uma partição dos diferentes pixels e um pixel líder é designado para cada um dos grupos que constituem a partição. Uma distância T é, então, calculada para cada pixel em relação aos líderes. Os grupos são enumerados e o algoritmo examina todos os pixels, atribuindo cada pixel ao primeiro grupo de cujo líder ele está suficientemente próximo, ou seja, a uma distância menor que o limiar considerado. O limiar é uma medida do diâmetro de cada grupo. Para os pixels que não estejam suficientemente próximos dos líderes existentes, é criado um novo grupo e é designado um novo líder (HARTIGAN, 1975).

Esse algoritmo é bastante eficiente, requerendo uma única passagem pelos dados. Entretanto, apresenta algumas limitações. Uma delas é que a partição é não invariante com relação à reordenação dos casos. O primeiro elemento examinado é sempre um líder de grupo. Uma outra, é que os primeiros grupos são sempre maiores que os últimos, uma vez que são os primeiros a serem analisados e, portanto, apresentam maiores chances que os elementos sejam alocados a eles.

4.5.3 Incorporação de Dados Auxiliares nos Métodos de Classificação

Os métodos tradicionais de classificação de imagens digitais obtidas por sensoriamento remoto, baseiam-se em características espectrais, sendo cada pixel classificado independente de seus vizinhos, podendo acarretar erros no resultado da classificação.

Em função disso, têm-se sugerido procedimentos que levam em consideração as informações dos pixels vizinhos ou características da região, ou seja, consideram a incorporação de dados auxiliares. Como exemplo de dados auxiliares, cita-se o conhecimento prévio dos tipos de uso da terra para agricultura, que poderão servir no inventário dos tipos de culturas em anos posteriores; a distribuição espacial de certos tipos de florestas baseada no seu

aspecto e/ou características topográficas; os modelos numéricos de terrenos para classificações de áreas montanhosas, etc.

De acordo com JENSEN(1986), várias abordagens têm sido desenvolvidas para incorporar dados auxiliares nos processos de classificação.

Uma alternativa, considerada eficiente, de incorporação de informações a partir de fontes de dados auxiliares no processo de classificação, foi desenvolvida por RICHARDS et al in JENSEN(1986). Nesse método, primeiro é feito um estudo prévio dos vários aspectos considerados importantes na área. Então, informações contextuais podem ser incorporadas ao processo de classificação. O contexto de um pixel refere-se à sua relação espacial com os demais pixels da imagem. Dessa forma, observa-se que as regras de decisão contextual podem envolver outros pixels ou grupos de pixels contidos na imagem.

O método acima citado baseia-se em procedimentos de relaxação de rótulos probabilísticos, os quais, são usados para envolver dados contextuais espaciais em problemas de rotulação de imagens. Além disso, informações auxiliares são usadas, como um conjunto de probabilidades que são inseridas em um método de relaxação modificado, chamado de rotulação de relaxação supervisionada. De acordo com o autor, esse método apresentou uma melhoria de 68 a 81% na precisão de classificações de florestas quando informações auxiliares topográficas foram incorporadas.

Para JENSEN (1986), a incorporação de dados auxiliares e contextuais, no processo de classificação, é uma importante alternativa para os classificadores que se baseiam somente na análise da informação espectral de cada pixel. O autor ressalta, entretanto, que a escolha das variáveis a serem incluídas é crítica. Sugere que o analista deveria selecionar somente aquelas variáveis com significado prático e conceitual para os objetivos a serem alcançados no processo de classificação, pois a incorporação de informações auxiliares redundantes pode não ser útil para o processo de classificação, além de consumir os recursos disponíveis para a análise de dados.

4.5.4 Medida da Precisão da Classificação

Ao término do processo de classificação de uma imagem digital obtida por sensoriamento remoto, é necessário ter-se uma medida de precisão dos resultados alcançados. Dessa forma, é possível atribuir um grau de confiança aos resultados, servindo como indicativo para a análise efetuada.

A precisão pode ser determinada empiricamente, requerendo, para tanto, um mapa da "verdade terrestre" para ser comparado com o mapa obtido da classificação. O mapa da "verdade terrestre" pode ser obtido de um conhecimento a priori ou de trabalhos de campo, ou, ainda, a partir da interpretação de dados de sensoriamento remoto de alta resolução ou de escalas grandes.

Para atribuir a precisão da classificação pode-se, então, avaliar a concordância da área total, em cada categoria, dos mapas envolvidos. Esse procedimento não avalia os erros de compensação nas várias categorias. Por esse motivo, ARONOFF em JENSEN (1986) sugere que a análise comparativa de áreas específicas (matrizes de erro) pode proporcionar melhores resultados do que a comparação de toda a área.

Para análise de áreas específicas (matrizes de erro), compara-se a precisão do mapa de classificação derivado dos dados de sensoriamento remoto, pixel a pixel, com o mapa assumido como verdade terrestre.

Para avaliação desses erros, é possível basear-se somente nos pixels das áreas de treinamento, que são aqueles utilizados para treinar o classificador. Isso significa que os pixels usados para treinar o classificador são cuidadosamente avaliados em ambos os mapas. Normalmente, essas áreas de treinamento são escolhidas pelo analista, levando em consideração o seu conhecimento em relação aos tipos de cobertura que existem na área. Entretanto, esse fato pode conduzir à escolha de amostras tendenciosas e, dessa forma, não representativas da área de estudo. Devido a essa ^{pele}representatividade, a precisão da classificação para os pixels das áreas de treinamento é, geralmente, maior do que a dos pixels do restante da cena. Portanto, para uma melhor precisão da classificação, as áreas de treinamento devem ser distribuídas aleatoriamente. Por outro lado, se outras áreas de treinamento são identificadas e corretamente

rotuladas a priori para classificação, e se essas não são utilizadas no treinamento do classificador, elas podem ser usadas para avaliar a precisão da classificação.

Para uma rigorosa avaliação dos erros ter-se-ia que verificar cada pixel do mapa da classificação derivada de dados de sensoriamento remoto com o seu correspondente no mapa de "verdade terrestre". Esse procedimento, no entanto, torna-se impraticável, quando a classificação for de uma extensa área. Entretanto, para pequenas áreas, onde a ênfase for para técnicas de desenvolvimento ou entendimento das vantagens e desvantagens de classificação multiespectral, esse método torna-se vantajoso. Nesse caso, é necessário identificar a classe designada para cada pixel em ambos os mapas. Esses dados deverão ser reportados para uma "matriz confusão", onde a precisão da classificação e as misturas de classificação, entre categorias, são identificadas. Normalmente, essa matriz é da forma $m \times m$, onde m é o número de classes em investigação, sendo que as linhas da matriz representam as classes da "verdade terrestre" e as colunas são associadas com as classes do mapa obtido pela classificação dos dados (ou vice-versa). Uma das características mais importante dessas matrizes é o fato de resumir os erros de inclusão (um pixel que não pertence à classe de interesse foi a ela atribuído) e de omissão (quando um pixel que pertence à classe de interesse não foi a ela atribuído). Os elementos da diagonal da matriz representam o número de pixels corretamente classificados. Os elementos acima da diagonal representam os erros de omissão e os abaixo da diagonal os de inclusão.

A partir da "matriz confusão", pode-se calcular o índice de precisão total da classificação. O coeficiente kappa é usado como um índice de precisão total da classificação. É recomendado como uma medida de precisão adequada em classificação temática, por representar toda matriz de confusão. Esse índice pode ser expresso por:

$$\hat{K} = \frac{p_0 - p_c}{1 - p_c} \quad (4.41)$$

Onde: p_0 = representa a proporção de unidades observadas com classificação correta, e é calculado como:

$$p_0 = \sum_{i=1}^m p(i, i) \quad (4.42)$$

p_c = representa a proporção esperada de unidades com classificação correta, e, é calculado como:

$$p_c = \sum_{i=1}^m p(i, +) p(+, j) \quad (4.43)$$

A fim de examinar a precisão da classificação, classe por classe, foi derivado o coeficiente Kappa condicional (GONG e HOWARTH, 1992), pela comparação dos resultados da classificação com os dados de referência (verdade terrestre). O coeficiente Kappa condicional é a precisão da classe, derivada da concordância entre a i -ésima linha e i -ésima coluna na matriz confusão para uma classe particular. Esse coeficiente é calculado através da seguinte fórmula:

$$K_i = \frac{P(i,i) - P(i,+) P(+,j)}{P(i,+) - P(i,+) P(+,j)} \quad (4.44)$$

4.5.5 Abordagens Atuais e Perspectivas de Novos Desenvolvimentos

Os métodos tradicionais de classificação são baseados em características espectrais. Pesquisas vêm sendo realizadas com o propósito de desenvolver algoritmos que incorporem atributos espaciais, variações temporais e dados auxiliares.

MASCARENHAS E VELASCO (1989) apontam, como as principais técnicas que incorporam atributos espaciais, a filtragem espacial, para a extração de atributos locais, os quais serão agregados aos atributos espectrais; a análise de textura, sendo essa realizada por processos estocásticos bidimensionais ou por matrizes de co-ocorrência, que são histogramas bidimensionais de níveis de cinza para uma dada distância e dada direção; a segmentação de cenas, classificando elementos de imagens por grupos e, ainda, a teoria de decisão composta (essa teoria leva em consideração a correlação de elementos adjacentes na classificação).

Algoritmos que incorporam características temporais são aqueles que permitem manipular imagens de diferentes datas. Para que a análise multitemporal dê bons resultados, torna-se necessário o registro preciso das diferentes passagens. Entre as várias técnicas de análise multitemporal, NOVO (1989) cita a subtração pixel a pixel dos valores digitais de duas cenas, obtendo uma "imagem-diferença". Essa imagem poderá, posteriormente, ser submetida a uma classificação, de tal modo que sejam identificadas áreas que, de uma data para outra, sofreram um aumento no valor do nível de cinza, áreas que não apresentam mudanças significativas e áreas que sofreram uma redução no valor do nível de cinza.

A incorporação de dados auxiliares baseia-se em informações, subjetivas e descritivas. Por exemplo, um dado auxiliar útil em um ambiente montanhoso é o modelo de elevação digital, o qual fornece variáveis (inclinação, altitude, etc.) que auxiliam no diagnóstico da área (FRANKLIN e WILSON, 1992). Outro exemplo são os mapas de classificação de anos anteriores, que podem ser usados na análise de alterações do meio físico. Pode-se citar, também, a utilização dos sistemas geográficos de informações, os quais incorporam dados auxiliares que, quando associados à imagem de satélite, proporcionam dados para o gerenciamento de recursos naturais.

Os métodos tradicionais de classificação de imagens funcionam adequadamente para os pixels que são bem representativos de cada uma das classes. Para pixels mistos, podem ocorrer distorções tanto nos cálculos dos parâmetros representativos da classe quanto no próprio processo de classificação. Essas distorções podem ocasionar confusão na atribuição correta de um pixel à classe. As abordagens atuais dadas aos métodos de classificação vêm tentando amenizar essas distorções, através do uso de informações auxiliares ou contextuais. Novas abordagens vêm sendo pesquisadas, com a introdução de elementos da teoria dos conjuntos difusos e de técnicas de inteligência artificial.

A introdução da teoria dos conjuntos difusos faz com que não haja perda de informações no processo de classificação, permitindo identificar-se pixels que são bem representativos de cada classe e pixels mistos (LAPOLLI et al 1991). O processo de classificação é executado a partir da função de pertinência. Para uma função de pertinência normalizada no intervalo [0, 1], os pixels que apresentam "grau de pertinência" igual à unidade, para uma determinada classe,

são considerados, bem representativos dessa classe. Pixels que apresentam "grau de pertinência" igual a 0, para uma determinada classe, não pertencem a essa classe. Pixels cujos "graus de pertinência" estão no intervalo (0,1), para mais de uma classe, são pixels considerados mistos.

A utilização de sistemas especialistas facilita o desenvolvimento de processos de análise de imagens. De acordo com MATSUYAMA (1989), os sistemas especialistas incorporam as técnicas de inteligência artificial para resolver os problemas de processamento de imagens. O conhecimento utilizado por esses sistemas está relacionado com a maneira de usar, efetivamente, os operadores de processamento de imagens na análise das mesmas. A especialização almejada no sistema se refere ao conhecimento que os pesquisadores adquirem por meio do desenvolvimento das técnicas de processamento de imagens. Os algoritmos convencionais de classificação de imagens, normalmente, fundamentam-se em medidas de similaridade, distância, etc. Com o uso de sistemas especialistas, pode-se incorporar ao processo de classificação o conhecimento do especialista. Assim, esses sistemas poderão servir para auxiliar outros analistas na "tomada de decisão".

O uso de redes neurais para a classificação de imagens digitais segue os princípios dos métodos de classificação supervisionados. É importante, devido às características das redes serem bastante tolerantes a desvios de padrões. Uma vez realizado o processo de aprendizado da rede neuronal, os novos dados não necessitam ser completamente especificados. As redes são capazes de reconhecer um pixel como pertencente a uma das classes, mesmo quando este não possui características exatamente iguais a nenhum dos pixels utilizados para o treinamento da rede. Para HEPNER et al (1990), a grande vantagem da utilização das redes neurais na classificação de imagens digitais reside no fato de que essas necessitam de um número menor de pixels no conjunto de áreas de treinamento, se comparado com os métodos convencionais.

4.5.6 Aplicações de Técnicas de Classificação

COGO (1993) utilizou atributos espaciais, em particular a textura, no processo de classificação digital de imagens. Realizou uma aplicação usando

uma imagem LANDSAT TM 5, bandas 3, 4 e 5, de 29/07/88, da região do Parque Nacional das Emas, no sul do Estado de Goiás. Quantificou as informações de textura pelo método das matrizes de co-ocorrência sugerido por HARALICK (1973). A partir da banda 3, criou 3 canais de textura e, a partir da banda 5, criou mais 3 canais de textura, utilizando esses canais na classificação, pelo método da máxima verossimilhança. Concluiu que a introdução dos atributos espaciais melhora a exatidão do processo de classificação.

LAPOLLI, ALVES e BARCIA (1993) compararam os métodos de classificação por máxima verossimilhança, distância euclidiana e paralelepípedo. Utilizaram uma imagem SPOT com três bandas (R, G e B), resultante da combinação das bandas multiespectrais e pancromática, tendo sido submetida a um processo de registro, filtragem e transformação IHS. Concluíram que, embora a automatização do processo seja desejável, a precisão depende fundamentalmente das amostras fornecidas, sendo muito importante o papel do analista dentro do processo.

Partindo do fato de que os métodos de classificação mais comumente empregados baseiam-se unicamente na informação espectral, deixando de lado aspectos fundamentais da interpretação, como forma, textura, posição relativa ou tamanho dos objetos na imagem, CENTENO e HAERTEL (1993) desenvolveram metodologias baseadas em processos de relaxação, com o objetivo de incluir atributos contextuais dentro do processo de classificação de imagens digitais. Utilizando uma janela móvel, extraíram as informações de contexto para cada pixel da imagem, representadas pela relação entre a sua resposta espectral e a de sua vizinhança imediata. Realizando experimentos com imagens sintéticas, mostraram que é possível melhorar a classificação digital de imagens de sensoriamento remoto, através da inclusão do conceito de contexto no processo, tornando as imagens temáticas resultantes mais apropriadas para análise.

Considerando que os métodos convencionais de classificação de dados de sensoriamento remoto levam a resultados insatisfatórios, devido às suas intrínsecas limitações, MASELLI, CONESE, PETKOV e RESTI (1992) propuseram a inserção de probabilidades a priori, derivadas de um processo não paramétrico, num classificador paramétrico convencional (classificador de máxima verossimilhança). Com isso, procuraram agregar as vantagens das estratégias paramétrica e não paramétrica. Aplicaram o método em duas imagens

LANDSAT TM de 26 de maio de 1988 e 14 de agosto de 1988, de uma região ao sudeste de Florença, na Itália. Concluíram que o procedimento proposto apresenta um desempenho melhor que os classificadores convencionais, em termos de precisão global e extensão da área classificada, especialmente quando as áreas de treinamento são pequenas,.

FOODY, CAMPBELL, TRODD e WOOD (1992) consideram que o classificador de máxima verossimilhança gera um montante considerável de informação que não é utilizada. A saída convencional é unicamente a classe a que o pixel é atribuído, baseada na máxima probabilidade. Propõem o uso de informação adicional, basicamente a probabilidade a posteriori e a tipicidade. Com essa informação, podem-se identificar pixels que são atípicos da classe a que foram atribuídos e dirigir as pesquisas de campo para regiões em que haja uma alta probabilidade de erros na classificação, classificando novamente esses pixels e melhorando o processo.

Com o objetivo de obter informação sobre o uso do solo, GONG e HOWARTH (1992) desenvolveram um método de classificação contextual. Usando um algoritmo de redução de dados através de rotação do espaço multiespectral, reduziram os vetores de níveis de cinza. Dessa forma, obtiveram imagens de uma só dimensão, com a perda de relativamente pouca informação. Cada imagem com os vetores de níveis de cinza reduzidos foi utilizada num procedimento baseado em frequências para derivar a informação sobre o uso do solo. O procedimento foi testado usando uma imagem HRV SPOT da franja rural-urbana de Toronto, Canadá. Utilizando o coeficiente Kappa, obtiveram uma precisão de classificação total de 0.616, definindo 14 classes de uso do solo. Comparado com o valor de 0.462 obtido para o mesmo coeficiente, aplicando o método da máxima verossimilhança, concluíram que a precisão pelo procedimento proposto era significativamente melhor. O classificador contextual desenvolvido também se mostrou eficiente, em termos computacionais.

Para segmentar uma imagem, PAL e GHOSH (1992) apresentam um conjunto de algoritmos, com base no conceito de correlação entre duas propriedades de uma imagem. A informação espacial é obtida pelas seguintes medidas: correlação transicional e correlação dentro da classe. Uma relação entre índice de difusão e coeficiente de difusão é teoricamente estabelecida e experimentalmente verificada. O algoritmo é testado em imagens que apresentam tipos diferentes de histogramas.

Para realizar a classificação de uma região montanhosa no sudoeste de Yukon, FRANKLIN e WILSON (1992) utilizaram informação de imagens de satélite e de modelos de elevação digital. Desenvolveram um método de classificação de três estágios, que incorpora um operador de segmentação por "quadtree", um teste gaussiano de mínima distância das médias, um teste envolvendo dados auxiliares de elevação digital e uma medida de curva espectral. Uma característica importante desse método de três estágios é que cálculos desnecessários são reduzidos: assim que um pixel ou região passa em um teste num determinado estágio, é classificado e não mais considerado nos estágios posteriores. O procedimento é um modo eficiente de incorporar dados auxiliares em um dos estágios. É feita uma tentativa de classificar os pixels com um mínimo de informação e somente quando nenhuma decisão pode ser tomada é que se utilizam os dados auxiliares. Mostraram que o classificador de três estágios produz um mapa de saída que requer significativamente menos tempo que o exigido num classificador pixel a pixel, usando um mínimo de campo ou dados de treinamento, o que geralmente é difícil de se obter em áreas complexas.

TREITZ, HOWARTH e GONG (1992), considerando que a suposição de normalidade e separabilidade, embutida nos classificadores convencionais; nem sempre é verdadeira em um ambiente urbano, utilizaram um método de classificação indireto. Com dados SPOT XS e PAN, num primeiro estágio realizaram a classificação pelo método da máxima verossimilhança, identificando 8 classes espectrais. Utilizando o resultado da classificação espectral, passaram a um segundo estágio, onde usaram um método baseado em frequências para chegar a uma classificação de uso e cobertura do solo. Esse segundo estágio envolveu três passos. No primeiro, uma janela de pixels de 11 por 11 foi aplicada sobre toda a imagem classificada. Dentro de cada janela de pixels, as frequências das 8 classes espectrais foram contadas e atribuídas ao pixel central, como características espaciais para a classificação final desse pixel. A seguir, as frequências médias das 8 classes espectrais foram extraídas das características de frequência de classe de uso e cobertura do solo definida, usando uma estratégia de amostragem de treinamento em bloco. Como resultado, foi calculada a proporção média de cada classe espectral dentro de uma classe de uso e cobertura do solo específica. Finalmente, as características de frequência para cada pixel foram classificadas de acordo com as frequências médias, usando um classificador de mínima distância. Concluíram que esse classificador de dois estágios melhora sensivelmente o processo.

Utilizando dados SPOT, foi realizado um estudo na região de Picos, Piauí, por TEOTIA, CIVCO, ULBRICHT e KENNARD (1991). Utilizaram um classificador híbrido: supervisionado e não supervisionado, em dois estágios. Usando inicialmente 33 áreas de treinamento, aplicaram um classificador de máxima verossimilhança e, após uma inspeção inicial, agregaram algumas categorias e desprezaram outras. Concluíram que, para o mapeamento do uso e da cobertura do solo, a combinação de métodos supervisionado e não supervisionado de classificação fornece bons resultados.

No monitoramento das mudanças ocorridas numa região, CHEN e CHEN (1991) utilizaram a combinação de dados de sensoriamento remoto temporais e espectrais. Baseados em procedimentos de classificação, analisaram simultaneamente as informações espectrais e temporais de uma imagem composta. Duas imagens multiespectrais, adquiridas aproximadamente à mesma época, em diferentes anos, foram combinadas através do registro imagem-imagem para formar uma imagem composta. Usando um método hierárquico, identificaram as classes nas regiões em que ocorreram mudanças.

Analisando o problema da classificação de imagens digitais, LAPOLLI, ALVES, BASTOS e LAPOLLI (1991) concluem que as técnicas usuais funcionam de forma adequada para pixels que são bem representativos de cada uma das classes, podendo haver distorções no caso de pixels mistos. Propõem o uso de conjuntos difusos e redes neuronais na tentativa de identificar os pixels mistos. Segundo os autores, o emprego de sistemas especialistas pode trazer vantagens, uma vez que podem ser usados para incorporar o conhecimento do analista no processo de classificação.

WANG (1990) considera que um fator importante, que degrada a análise de imagens de sensoriamento remoto, é a perda de informação durante o processo de classificação. Essa perda de informação é causada pela inadequação dos métodos tradicionais para representar informações geográficas. Para identificação e classificação dos pixels da imagem, propõe o uso de uma função de pertinência baseada na densidade de probabilidade de uma normal multivariada. A função de pertinência de um pixel a uma determinada classe, é obtida através de:

$$f_c(X) = \frac{P_c^*(X)}{\sum_{i=1}^m P_i^*(X)}$$

$$\text{Sendo: } P_c^*(X) = \frac{1}{(2\pi)^{n/2} |\Sigma_i^*|^{1/2}} e^{-1/2(X-\mu_i^*)^T \Sigma_i^{*-1} (X-\mu_i^*)}$$

A normalização adotada por Wang, acarreta em uma partição difusa do espaço espectral. Os pixels são atribuídos para as classes com maior valor de pertinência, independente desse valor ser muito pequeno ou não.

KLEIN e PRESS (1990) consideram o problema da classificação contextual bayesiana com estrutura de correlação espacial, em que os vizinhos de um vetor não classificado, e o próprio vetor não classificado, são correlacionados com o conjunto de dados de treinamento, e alguns vizinhos podem pertencer ao conjunto de dados de treinamento, caso em que se sabe pertencerem a uma particular população. Através de simulação, comparam o procedimento proposto com resultados anteriores, que ignoram a correlação entre o conjunto de dados de treinamento e os pontos próximos dos dados de treinamento, ou não permitem pontos no conjunto de dados de treinamento serem tratados como vizinhos. Concluem que a incorporação desse conhecimento adicional no processo de classificação melhora substancialmente a taxa de classificação correta.

VENTURIERI, FUNAKI e MEDEIROS (1990) utilizaram classificação supervisionada de imagens para mapeamento da cobertura vegetal e uso da terra na região de Tucuruí, Pará. Usaram uma imagem LANDSAT TM e a classificação foi feita pelo método da máxima verossimilhança. Concluíram que o processo apresentou um grau de exatidão satisfatório e que as principais limitações do uso estão condicionadas à heterogeneidade de algumas áreas, proporcionadas pelas diferentes formas de ocupação. Afirmaram que as limitações inerentes à classificação digital podem ser contornadas através da interpretação visual nas áreas não classificadas ou classificadas incorretamente.

GURNEY e TOWNSHEND (1983) realizaram uma análise dos diversos métodos de classificação contextual. Consideraram que esses métodos

são mais adequados para serem usados na classificação de áreas urbanas; na identificação de objetos lineares e na separação de nuvens e sombras de nuvens do restante da cena. Concluíram que, embora a informação contextual muitas vezes seja de substancial valor no processo de classificação, o projeto e uso de regras contextuais apropriadas depende, fundamentalmente, do conhecimento do analista acerca das relações espaciais realmente existentes na área e da relação entre o tamanho do pixel e tamanho do objeto dentro de uma cena.

Outros trabalhos que tratam de classificação de imagens digitais são os de ALVES, LAPOLLI, BASTOS e BASTOS (1993); BATISTA e FINAMORE (1993); SCHLÜNZEN, TRINDADE, SHIMABUKURO, SCHLÜNZEN JÚNIOR e ANDRADE NETO (1993); SILVA (1993a); SILVA (1993b); FRANZONI, ALVES, LAPOLLI e BASTOS (1993); McGWIRE (1992); AHEARN e WEE (1991); CETIN e LEVANDOWSKI (1991); CENTENO e HAERTEL (1991); HAMBURGER e FORESTI (1991); BOLSTAD e LILLESAND (1991); RASSON, ORBAN-FERAUGE e GRANVILLE (1991); ALVES, LAPOLLI, GAUTHIER e BARCIA (1991); LAPOLLI, ALVES, LOCH e BARCIA (1991); FONSECA, BINS, VELASCO e MONTEIRO (1990); HUMPHREYS (1990); UNSER e EDEN (1990); MOREIRA (1988); CARR, GLASS e SCHOWENGERDT (1983); CONGALTON, ODERWALD e MEAD (1983); HARALICK, SHANMUGAM e DINSTEN (1973).

4.6 Conclusão

O uso de técnicas de processamento digital de imagens aumenta consideravelmente a capacidade do analista de extrair informações da superfície terrestre, a partir de dados de sensoriamento remoto.

As imagens digitais são preprocessadas para reduzir as distorções nos dados causados pelo sensor. Inclui correção geométrica e radiométrica.

Para melhorar a qualidade das imagens, tanto para que elas possam posteriormente ser interpretadas pelo analista, quanto para ser utilizadas em um processo de classificação, várias técnicas de realce de imagens podem ser aplicadas.

Nos métodos de classificação de imagens digitais, as classes podem ser previamente determinadas, o que se denomina classificação supervisionada, ou podem ser determinadas a partir do próprio conjunto de dados, sendo, então, chamada de classificação não supervisionada. Ambos os modelos apresentam vantagens e desvantagens. O método supervisionado é subjetivo, dado que o analista tenta classificar informações que são compostas, na maioria das vezes, de muitas classes espectrais. O método não supervisionado, geralmente, resulta em agrupamentos espectrais que podem não ter um significado claro.

As imagens derivadas de dados de sensoriamento remoto apresentam uma melhoria na sua precisão, quando técnicas supervisionadas e não supervisionadas são agrupadas, sendo então denominada de classificação híbrida. Nesse método, a classificação não supervisionada é utilizada como base para a seleção de amostras de treinamento para realizar uma classificação supervisionada.

Verifica-se que, atualmente, existem muitas pesquisas em desenvolvimento e muitos estudos com a perspectiva de melhorar o resultado das classificações, sendo incorporados novos elementos e/ou utilizadas novas técnicas.

5. CONJUNTOS DIFUSOS EM PROCESSAMENTO DE IMAGENS DIGITAIS

5.1 Introdução

Entre as aplicações de sensoriamento remoto, a classificação de imagens é uma das mais importantes, sendo utilizada, principalmente, para a elaboração de mapas de uso/cobertura do solo. Esses mapas representam informações geográficas e cada região é associada com uma determinada classe de uso/cobertura do solo (solo exposto, vegetação, etc.). Assim, a maioria dos classificadores tem como meta a atribuição de cada pixel a uma classe. As informações geográficas, porém, não são precisas. Muito comumente, mais de uma classe está presente numa determinada área do terreno. A associação do pixel a uma única classe faz com que parte da informação disponível não seja considerada.

Neste capítulo, é proposta uma abordagem, baseada na teoria dos conjuntos difusos, para processamento de imagens digitais. Fazem parte da proposta um algoritmo de classificação difuso, bem como técnicas de manipulação das informações obtidas. Essa proposta é operacionalizada através de uma implementação computacional, objeto de análise do próximo capítulo.

Uma partição difusa do espaço espectral é inicialmente introduzida, dado que a abordagem desenvolvida fundamenta-se nesse conceito. A seguir, são apresentados os pontos essenciais do algoritmo. Após, o algoritmo completo é especificado. Ao final, discute-se como obter, com base na teoria dos conjuntos difusos, informações complementares importantes.

5.2. Partição Difusa do Espaço Espectral

Os pixels, numa imagem digital, são definidos pelo vetor cujos componentes são os níveis de cinza em cada uma das bandas espectrais. Assim, cada pixel representa um ponto no espaço espectral por elas definido.

Dado um conjunto de pixels X , classificá-lo significa atribuir um rótulo a cada ponto de X . Esses rótulos (classes, no caso de classificação de imagens digitais) podem apresentar limites perfeitamente definidos, não acarretando incerteza quanto à atribuição realizada. Nesse caso, classificar um pixel significa particionar o espaço espectral em regiões disjuntas e atribuí-lo a uma, e somente uma, das regiões, mediante o emprego de regras de decisão definidas precisamente (FIGURA 5.1).

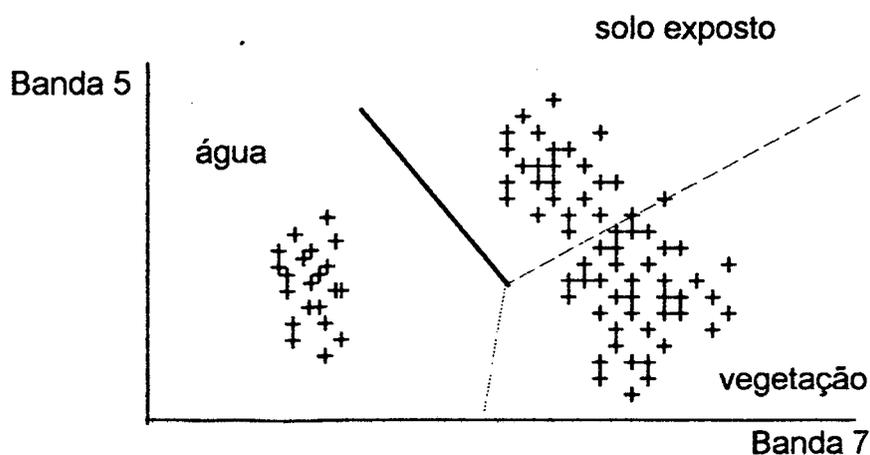


FIGURA 5.1 - Partição do Espaço Espectral

Contudo, como decorrência de imprecisões intrínsecas ao sistema real, as fronteiras entre as classes podem ser vagas ou difusas, conduzindo à impossibilidade de estabelecer critérios precisos (crisp) para as funções discriminantes. Conseqüentemente, um determinado pixel pode pertencer, simultaneamente, a mais de uma das classes utilizadas para particionar o espaço espectral. Nesse caso, o processo de classificação consiste em realizar uma partição difusa do espaço espectral. Essa partição difusa é representada numa matriz $[f_{ki}]$, onde $k = 1, \dots, c$, sendo c o número de classes e $i = 1, \dots, n$, sendo n o total de pixels observados na imagem (Equação 5.1).

$$\begin{bmatrix} f_{11} & f_{12} & \dots & f_{1n} \\ f_{21} & f_{22} & \dots & f_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ f_{c1} & f_{c2} & \dots & f_{cn} \end{bmatrix} \quad (5.1)$$

Uma representação esquemática dessa partição difusa do espaço espectral pode ser observada na FIGURA 5.2. Os círculos concêntricos representam cortes nas funções de pertinência das classes correspondentes. Os valores de pertinência variam inversamente ao comprimento do raio. É observada, nessa figura, a sobreposição de classes em alguns pixels, o que caracteriza os casos em que existe possibilidade de um pixel conter mais de uma classe.

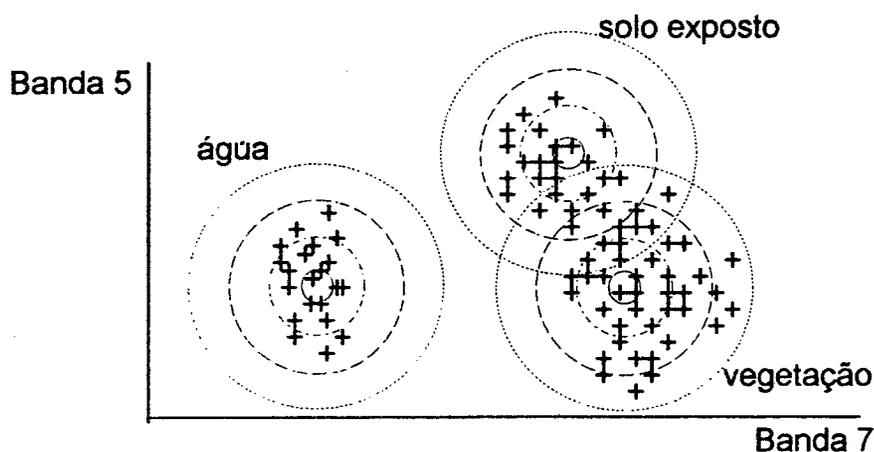


FIGURA 5.2 - Partição Difusa do Espaço Espectral

5.3 Algoritmo para Classificação Difusa

No algoritmo proposto, toda a informação disponível é utilizada para determinar as pertinências do pixel às diferentes classes.

5.3.1 Função de Pertinência Utilizada no Algoritmo para Classificação Difusa

O algoritmo apresentado baseia-se no método de classificação por máxima verossimilhança. O algoritmo de máxima verossimilhança parte do pressuposto de que os níveis de cinza de cada classe seguem uma distribuição multivariada (em geral a distribuição normal) e a sua regra de decisão consiste em atribuir o pixel à classe onde $p(x/c_j)p(c_j)$ seja máximo. Por trabalhar com partições do espaço espectral no contexto da teoria clássica dos conjuntos, esse algoritmo atribui pertinência 1 à classe onde $p(x/c_j)p(c_j)$ é máximo e nenhuma pertinência às demais classes. A aplicação dessa regra de decisão deixa de lado informações importantes sobre as probabilidades de o pixel pertencer a outras classes.

A existência de probabilidades não nulas em outras classes leva a supor que existem pertinências não nulas a essas classes. A abordagem proposta considera que, para realizar a classificação, deve-se criar uma partição difusa do espaço espectral. Com essa finalidade, a pertinência do pixel a uma classe é definida como:

$$f_c(x) = \frac{P_c^*(x)}{\sum_{i=1}^n P_i^*(x)} \quad (5.2)$$

Onde: f_c = função de pertinência

P_c^* = probabilidade do pixel pertencer à classe c

n = número de classes

Se for considerado que os níveis de cinza dos pixels seguem um modelo normal multivariado para cada uma das diferentes classes, a probabilidade em cada uma das classes pode ser estimada como sendo:

$$P_c^* = \frac{1}{(2\pi)^{N/2} |\Sigma_i^*|^{1/2}} \exp\left(-\frac{1}{2}(X - \mu_i^*)^T \Sigma_i^{*-1} (X - \mu_i^*)\right) \quad (5.3)$$

Onde: μ_i^* = média difusa

Σ_i^* = matriz de covariâncias difusa

Além disso, dado que as probabilidades podem ser extremamente baixas, o que, em termos práticos, significa que a pertinência à classe é nula, é estabelecido um limiar semelhante ao utilizado no método da máxima verossimilhança. Ou seja,

$$\text{se } P_c^*(x) < \text{limiar} \Rightarrow P_c^*(x) = 0$$

No caso das probabilidades serem nulas para todas as classes, o algoritmo atribui o pixel a uma classe genérica chamada *outras*. Essa classe *outras* representa as classes que não foram consideradas no treinamento ou que o analista não considera importantes para o seu objetivo.

A existência desse limiar previne possíveis distorções. Por exemplo, considere-se o caso de 3 classes e os seguintes valores para a função densidade de probabilidade multivariada: $p_1=0.00000001$, $p_2=0.000000000001$ e $p_3=0.0000000000001$. Se não existir um limiar, o classificador irá atribuir o pixel à classe 1 com pertinência bem próxima a 1.0.

Outro problema que ocorre, se não for considerada existência de um limiar, é um elevado número de "underflows" na implementação computacional. Isso é consequência da existência de pixels que realmente não pertencem às classes definidas e, portanto, com probabilidades praticamente nulas de pertencer a uma das classes consideradas pelo analista.

5.3.2 Cálculo dos Parâmetros da Distribuição Multivariada

Para calcular as diferentes probabilidades, é necessário estimar os parâmetros das distribuições multivariadas de cada classe, a partir de uma amostra de treinamento.

Diferentemente do método da máxima verossimilhança, no algoritmo proposto considera-se que a ocorrência de um pixel numa classe é um evento difuso. Assim, os pixels de treinamento constituem uma partição difusa e são considerados nas médias e matrizes de covariâncias de forma diferente, em função da sua pertinência à classe.

Pelo princípio da consistência possibilidade-probabilidade, os parâmetros utilizados no algoritmo proposto podem ser obtidos a partir das definições de probabilidade de um evento difuso.

Sendo A um evento difuso, uma medida de probabilidade para A pode ser definida como:

$$P(A) = \int_A f_A(x) dP \quad (5.4)$$

Onde: f_A = função de pertinência

$$dP = \begin{cases} p(x)dx & \text{se } x = \mathfrak{R} \\ p(x) & \text{se } x \text{ é discreto} \end{cases}$$

A equação (5.4) é a integral de Lebesgue-Stieltjes e, se o evento não for difuso, a equação representa a probabilidade tradicional.

A partir da definição da medida de probabilidade para A, obtêm-se, diretamente, os valores de média e variância difusas de A (ZIMMERMAN, 1985). Considerando a existência de c classes em uma imagem, os conceitos de média e variância difusas podem ser generalizados, obtendo-se:

$$\mu_i^* = \frac{\sum_{i=1}^n f_c(X_i) X_i}{\sum_{i=1}^n f_c(X_i)} \quad (5.5)$$

$$\Sigma_c^* = \frac{\sum_{i=1}^n f_c(X_i) (X_i - \mu_c^*) (X_i - \mu_c^*)^t}{\sum_{i=1}^n f_c(X_i)} \quad (5.6)$$

5.3.3 Cálculo das Pertinências dos Pixels da Amostra

Para se calcular a média difusa e as covariâncias difusas, é necessário conhecer-se a pertinência de cada pixel da amostra em cada classe. Essa pertinência pode ser fornecida pelo analista, porém sua determinação não é trivial. Assim, define-se que essas pertinências são também função da probabilidade.

O algoritmo estima, a partir da amostra, as diferentes funções de probabilidade, para permitir a determinação da pertinência de cada um dos pixels da amostra a cada uma das classes.

5.3.4 Algoritmo de Classificação Difusa

O algoritmo desenvolvido compreende os seguintes passos:

1. INICIALIZAR - Definir as b bandas que serão usadas no processo de classificação, as k classes, associando um nome e uma cor a cada classe, bem como a composição colorida em que serão selecionadas as áreas de treinamento.
2. SELECIONAR ÁREAS DE TREINAMENTO - Delimitar, na composição colorida, áreas de treinamento para as diversas classes.
3. CALCULAR PARÂMETROS - Repetir passos 4 a 10 para cada uma das classes.
4. CALCULAR VETOR DE MÉDIAS - Calcular as médias (\bar{X}_i), por banda, dos níveis de cinza de cada classe, utilizando todas as áreas de treinamento da classe, pela fórmula:

$$\bar{X}_i = \frac{1}{n} \sum_{L=1}^n x_{iL}$$

Onde: x_{iL} = nível de cinza do pixel L na banda i, na classe considerada
 n = número total de pixels considerando todas as áreas de treinamento da classe

5. CALCULAR MATRIZ DE COVARIÂNCIAS - Calcular a matriz de covariâncias (S_c) das bandas, em cada classe, sendo cada elemento $s_c(i, j)$ dessa matriz obtido usando a seguinte fórmula:

$$s_c(i, j) = \frac{\sum_{L=1}^n (x_{iL} - \bar{x}_i)(x_{jL} - \bar{x}_j)}{n-1}$$

Onde: x_{iL} = nível de cinza do pixel L na banda i, na classe c
 \bar{x}_i = média do nível de cinza na banda i, na classe c
 n = número total de pixels, considerando todas as áreas de treinamento da classe c

6. CALCULAR INVERSA - Calcular a inversa da matriz de covariâncias das bandas em cada classe (S_c^{-1}).
7. CALCULAR DETERMINANTE - Calcular o determinante da matriz de covariâncias das bandas ($|S_c|$).
8. DETERMINAR A FUNÇÃO DENSIDADE DE PROBABILIDADE MULTIVARIADA - Determinar o valor da função densidade de probabilidade $g_c(x)$ para cada pixel das amostras de treinamento da classe, pela seguinte fórmula:

$$g_c(x_i) = \frac{1}{(2\pi)^{n/2} |S_c|^{1/2}} e^{-\frac{1}{2}(x_i - \bar{x}_c)^T S_c^{-1} (x_i - \bar{x}_c)}$$

Onde: x_i = vetor dos níveis de cinza do pixel
 S_c = matriz de covariâncias da classe c
 \bar{x}_c = vetor de médias da classe c
 n = número total de pixels, considerando todas as áreas de treinamento da classe c

9. CALCULAR VETOR DE MÉDIAS DIFUSAS - Calcular as médias difusas (μ_i^*) por banda, dos níveis de cinza de cada classe, utilizando todas as áreas de treinamento da classe, da seguinte forma:

$$\mu_i^* = \frac{\sum_{L=1}^n g_c(x_{iL})x_{iL}}{\sum_{L=1}^n g_c(x_{iL})}$$

Onde: g_c = função densidade de probabilidade multivariada da classe c
 x_{iL} = nível de cinza do pixel L na banda i , na classe c
 n = número total de pixels, considerando todas as áreas de treinamento da classe c

10. CALCULAR A MATRIZ DE COVARIÂNCIAS DIFUSA - Calcular a matriz de covariâncias difusa da classe c , (Σ_c^*), pela seguinte fórmula:

$$S_c^* = \frac{\sum_{i=1}^n g_c(x_i)(x_i - \mu_c^*)(x_i - \mu_c^*)^T}{\sum_{i=1}^n g_c(x_i)}$$

Onde: g_c = função densidade de probabilidade multivariada da classe c
 x_i = vetor de níveis de cinza do pixel i
 μ_c^* = vetor de médias difusas da classe c
 n = número total de pixels, considerando todas as áreas de treinamento da classe c

11. ATRIBUIR PERTINÊNCIAS AOS PIXELS DA IMAGEM - Para cada pixel da imagem, calcular a pertinência a cada uma das classes, da seguinte forma:

$$f_c(x_i) = \frac{P_c^*(x_i)}{\sum_{L=1}^k P_L^*(x_i)}$$

$$\text{Onde: } P_L^*(x_i) = \frac{1}{(2\pi)^{n/2} |\Sigma_L^*|^{1/2}} e^{-\frac{1}{2}(x_i - \mu_L^*)^T \Sigma_L^{*-1} (x_i - \mu_L^*)}$$

x_i = vetor de níveis de cinza do pixel i

μ_L^* = vetor de médias difusas da classe L

Σ_L^* = matriz de covariâncias difusas da classe L

n = número total de pixels, considerando todas as áreas de treinamento da classe L

5.4 Manipulação de Informações Obtidas pelo Método de Classificação

A abordagem de conjuntos difusos para classificação de imagens digitais oferece uma variedade de informações que não são consideradas por outros métodos. Na aplicação do algoritmo de classificação proposto, tem-se como resultado uma partição difusa do espaço espectral. Com o estabelecimento de conceitos e operações complementares sobre os resultados obtidos, novas informações, não disponíveis nos métodos tradicionais, tornam-se prontamente acessíveis.

5.4.1 Imagens de Pertinência

Nos algoritmos tradicionais de classificação, o resultado é apenas um rótulo para cada pixel, que identifica a qual classe ele pertence. Em outras palavras, o algoritmo fornece uma partição do espaço espectral que, em termos práticos, é representada numa imagem onde cada classe é identificada por uma cor.

Como resultado da aplicação do algoritmo proposto, obtém-se uma partição difusa do espaço espectral. Nota-se, entretanto, que o pixel pode pertencer a mais de uma classe. Não existe uma forma direta de representar visualmente essa partição. Por outro lado, a partição contém um volume

considerável de informações que devem ser manipuladas e armazenadas. Com o objetivo de superar essas dificuldades, é proposto o conceito de imagem de pertinência. Uma imagem de pertinência consiste numa imagem onde é representada a pertinência de cada pixel a uma determinada classe. Para trabalhar com as pertinências dos pixels nessa banda, é realizada uma mudança de escala de $[0,1]$ para $[0,255]$ nos valores de pertinência. Essa transformação faz com que as pertinências possam ser visualizadas como diferentes níveis de cinza, além de permitir a utilização de rotinas comumente empregadas na manipulação e no armazenamento de bandas espectrais.

5.4.2 Imagem Classificada de Nível Alfa

Um produto importante do processo de classificação é uma imagem, onde a cada pixel é associada uma cor, segundo a classe à qual pertence. Para obter-se, na classificação difusa, um produto semelhante, propõe-se o conceito de *imagem classificada a um nível alfa*. Nessa imagem, os pixels, cuja pertinência a uma classe seja maior ou igual ao nível alfa, são representados com a cor designada a esta classe. Para compor essa imagem, realiza-se um corte alfa em cada uma das imagens de pertinência. O corte de nível alfa das imagens de pertinência é o conjunto de todos os pixels que possuem pertinência maior ou igual ao valor especificado por alfa.

As imagens de pertinência constituem uma partição difusa. Para um determinado pixel, a soma das pertinências em todas as classes é igual à unidade e, como consequência, existe, no máximo, uma classe na qual ele possui pertinência maior que 0.5. Em termos de visualização da imagem, pode-se designar a esse pixel a cor definida para aquela classe.

Várias imagens classificadas a diferentes níveis alfa, no intervalo $(0.5;1.0]$, podem ser obtidas. Nas imagens obtidas pela variação dos cortes alfa, para o nível alfa adotado, tem-se o grau mínimo de veracidade ou possibilidade de que o pixel pertença à classe na qual está representado.

Este tipo de representação permite identificar os pixels que, a um determinado nível de possibilidade, constituem mistura de classes. Os pixels cujo

grau de pertinência máximo não é superior ao nível alfa estabelecido, podem ser considerados pixels mistura. Na implementação, foi reservada a cor branca para esses pixels.

5.4.3 Determinação do Contexto Difuso de um Pixel

Em algumas aplicações de processamento digital de imagens, é importante a consideração do contexto onde o pixel se insere, pois esse fato pode evidenciar características e propriedades presentes no pixel.

O contexto é definido como a relação entre as características de um pixel e sua vizinhança imediata. Em termos práticos, para a extração de informações contextuais, inicialmente define-se uma janela móvel de tamanho $m \times m$, que é centralizada sobre todos os pixels da imagem. As características de interesse de todos os pixels que compõem a janela são combinadas e seu resultado é atribuído ao pixel central.

A teoria dos conjuntos difusos fornece técnicas que permitem levantar este tipo de informação. Através da partição difusa, é possível calcular a pertinência média de um contexto em cada uma das classes, atribuindo esse valor como pertinência ao pixel central de uma janela. Desse modo, a informação referente à vizinhança de um pixel é utilizada para calcular uma medida relativa a ele.

Como exemplo, tem-se o caso de identificação de um padrão, que consiste em determinar, numa certa região, formada por um conjunto de pixels, a mistura de classes existente. Nesse caso, não é importante somente conhecer a mistura de classes no pixel, mas no contexto em que ele se insere. A informação contextual (pertinência média) é que irá determinar se o pixel pertence ou não ao padrão considerado.

5.4.4 Similaridade Difusa

Uma medida de similaridade mede o grau de proximidade ou semelhança entre dois conjuntos. Se os dois conjuntos são difusos, essa proximidade é medida pela similaridade difusa, definida da seguinte forma (DUBOIS e PRADE, 1980):

$$\text{Similaridade} = \frac{\|A \cap B\|}{\|A \cup B\|} \quad (5.7)$$

$$\text{Sendo: } \|A\| = \frac{|A|}{|X|}$$

Onde: $\|A\|$ = cardinalidade relativa de A

$|A|$ = cardinalidade de A, ou seja, $\sum_A f_A$

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

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

A similaridade difusa entre dois conjuntos varia de 0, para conjuntos totalmente diferentes, a 1, para conjuntos totalmente iguais.

No exemplo anteriormente citado de determinação de um padrão, se for considerado o conjunto das classes presentes no pixel (extraído da informação do contexto), como um conjunto difuso, e o padrão, como outro conjunto difuso, pode-se determinar o grau de similaridade entre eles. Essa avaliação não pode ser muito rígida, deixando de lado pixels que estão próximos ao padrão desejado. Em vista disso, decide-se que o pixel é considerado como pertencente ao padrão se a medida de similaridade difusa entre ele e esse padrão estiver acima de um determinado limiar.

5.4.5 Áreas a Diferentes Níveis de Pertinência

Uma informação importante na análise de imagens digitais é a determinação das superfícies ocupadas por cada classe. A classificação através do algoritmo difuso permite determinar a área ocupada pela classe a um nível de pertinência. Isto é conseguido, realizando-se um corte alfa na partição difusa (como anteriormente descrito).

A estimativa da área a diferentes níveis alfa é importante, pois permite ao decisor ter um conhecimento sobre a imprecisão presente na sua avaliação.

Um exemplo pode esclarecer essa importância. Na FIGURA 5.3, a área representada pelo gráfico A possui menos difusão que a área do gráfico B. Considere-se um investimento que tem na área sua variável principal e é da forma $Inv = 2 \times \text{área}$. Com um grau de pertinência 1.0 para ambas as áreas, o investimento será de 20 unidades monetárias. Já com pertinência 0.6, tem-se, respectivamente, 40 e 84. Assim, uma decisão tomada levando-se em conta a área ocupada é, no segundo caso, bem mais imprecisa.

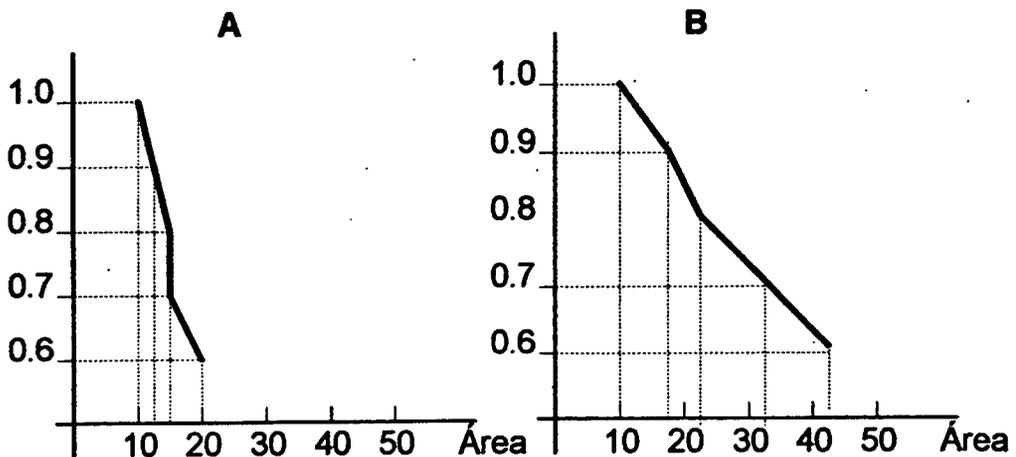


FIGURA 5.3 - Exemplo de Duas Áreas a Diferentes Níveis Alfa

5.5 Conclusão

O capítulo apresenta uma abordagem para classificação de imagens digitais baseada na teoria dos conjuntos difusos.

Um algoritmo para classificação é proposto e discutido. Os resultados desse algoritmo, apresentados sob a forma de partição do espaço espectral, possibilitam a obtenção de novas e relevantes informações.

Os algoritmos para classificação de imagens digitais baseados na teoria de conjuntos difusos encontrados na literatura, ao considerar apenas o conceito de partição rígida do espaço espectral, apresentam perda substancial de informação. Em termos gerais, os resultados desses algoritmos aproximam-se dos resultados dos métodos fundamentados em conceitos clássicos de estatística e probabilidade. Uma das principais vantagens do uso da lógica difusa no processamento de imagens digitais - a identificação de pixels mistura - não é viável, quando se adota uma partição rígida do espaço espectral.

A introdução do conceito de limiar para o valor de pertinências, durante o processo de classificação, reduz, consideravelmente, a perspectiva de obtenção de classificações erradas. A introdução desse limiar implica em restringir a atribuição, em alguma das classes previamente definidas, de um pixel que apresente probabilidades desprezíveis em todas as classes. Diversas podem ser as causas que originaram essas probabilidades desprezíveis: o pixel pode estar associado a uma classe que não seja de interesse do analista; o nível de cinza pode ter sido alterado por alguma razão, quando da obtenção da imagem; as amostras definidas para estimação dos parâmetros utilizados no algoritmo ter sido mal coletadas; etc.

O tratamento das informações fornecidas pelo classificador difuso é um ponto fundamental. No capítulo, foram apresentadas diversas formas para a realização desse tratamento.

O conceito de imagens de pertinência permite diversas análises com os resultados fornecidos pelo algoritmo. Uma imagem de pertinência, conforme conceituado nesse capítulo, consiste numa imagem onde é representada a pertinência de cada pixel a uma determinada classe. Após uma

mudança de escala dos valores de pertinência, é possível visualizar os valores de pertinência calculados como diferentes níveis de cinza. Além dessa visualização, as imagens de pertinência podem ser utilizadas nas rotinas comumente adotadas para a manipulação e o armazenamento de bandas espectrais.

Outro importante resultado derivado do algoritmo proposto é uma imagem classificada a um nível alfa. Nas imagens obtidas pela variação dos cortes alfa, para o nível alfa adotado, tem-se o grau mínimo de veracidade ou possibilidade de que o pixel pertença à classe na qual está representado. Como citado, essa representação permite identificar os pixels que, a um determinado nível de possibilidade, constituem mistura de classes. Na implementação computacional desenvolvida, foi reservada a cor branca para esses pixels.

6. EDIMA: SISTEMA COMPUTACIONAL PARA ANÁLISE E TRATAMENTO DE IMAGENS DIGITAIS

6.1 Introdução

As atividades relacionadas à análise espacial com auxílio de computadores pessoais podem ser consideradas limitadas por diversas razões. Entre as condições limitantes do uso de computadores em análises espaciais, três podem ser consideradas básicas (WELCH, 1989 e OLIVEIRA, 1990):

- custo de hardware e software;
- complexidade dos pacotes de softwares disponíveis;
- limitações na funcionalidade do software e tecnologias disponíveis.

Em HADAD e VELASCO (1990), é apresentado um sistema de processamento de imagens que procura solucionar duas das dificuldades no uso de tais sistemas: o alto custo do hardware para visualização de imagens e a complexidade das tarefas de processamento de imagens (via construção de sistemas especialistas).

Com o objetivo de criar um ambiente computacional robusto, que proporcionasse condições de desenvolvimento de aplicações de técnicas de processamento digital, integrasse os recentes desenvolvimentos teóricos na área de tratamento digital de imagens e que suprisse algumas das deficiências anteriormente mencionadas, o sistema EDIMA foi desenvolvido. Durante todo o processo de desenvolvimento do sistema computacional, a preocupação básica observada foi a de que o mesmo fosse flexível.

6.2 Modelo Computacional para Processamento de Imagens

Embora, existam vários métodos para o desenvolvimento de sistemas computacionais (BOOCH, 1991), todos eles apresentam como características comuns:

- **Notação:** ou seja a utilização de uma linguagem para expressar cada modelo;
- **Processo:** constituindo-se das linhas mestras que permitem a construção ordenada de modelos;
- **Ferramentas:** um conjunto de procedimentos que eliminam rotinas tediosas presentes na construção de modelos e estabelecem regras próprias para a sua construção.

6.2.1 Desenvolvimento através de Orientação a Objetos

O modelo computacional para processamento de imagens foi construído a partir dos paradigmas da orientação a objeto.

A metodologia de orientação a objetos define uma notação e um processo para a construção de sistemas computacionais complexos. Realça a importância de extrair explicitamente uma hierarquia de classes e objetos do sistema que está sendo modelado, bem como a necessidade de visualizar, previamente, decisões que permitam a incorporação de todos os atributos de um sistema complexo bem estabelecido (hierarquia; componentes primitivos; relacionamento intra-componentes; composição em subsistemas e evolução (COURTOIS, 1985).

6.2.2 Características Básicas do Modelo Computacional

O paradigma de orientação a objetos apresenta, como básicos, os seguintes princípios: abstração, encapsulamento, modularidade e hierarquia.

Uma abstração representa uma característica essencial de um objeto, tendo a capacidade de distingui-lo de qualquer outro tipo de objeto, conferindo-lhe limites conceituais rigidamente definidos. No sistema desenvolvido, por exemplo, uma imagem classificada que seja apresentada, exige a construção de uma base para a imagem, que se constitui de uma "*janela*" para a sua apresentação.

Através do encapsulamento, todos os detalhes de um objeto que não contribuem para suas características essenciais são ocultados. No sistema desenvolvido, os mecanismos de inicialização da "*janela*" e de sua montagem são transparentes.

Por modularidade subentende-se a propriedade que um sistema apresenta em poder ser decomposto em um conjunto de módulos coerentemente fragmentados e encaixados. Por exemplo, assim como foi definido um módulo para leitura e gravação de arquivos, existem módulos especializados no tratamento de imagens, classificação, etc. A modularidade é importante, principalmente, em termos da evolução e manutenção de um sistema computacional complexo.

A hierarquia representa uma classificação das abstrações realizadas. No modelo desenvolvido, um exemplo típico é dado pela função "*zoom*".

6.2.3 Ambiente de Desenvolvimento do Modelo Computacional

O ambiente de desenvolvimento é responsável por duas novas características, essenciais em um sistema computacional complexo: portabilidade e comunicabilidade ("user-friendly"). A portabilidade permite que o sistema seja

utilizado em outras plataformas que não a de desenvolvimento. A comunicabilidade usuário versus sistema computacional deve satisfazer os seguintes requisitos:

- o sistema deve possibilitar um processo de aprendizado simples e eficiente, facilitando sua utilização final;
- as funções do sistema devem estar acessíveis através de um número mínimo de passos;
- o sistema deve fornecer a maior quantidade possível de informações gráficas, tornando o processo de análise o mais simplificado possível.

O modelo computacional para análise e tratamento de imagens digitais foi desenvolvido utilizando-se a linguagem C++ da Borland Inc. e o sistema operacional Windows 3.1. Através dessa escolha, conseguiu-se satisfazer os requisitos propostos inicialmente.

6.2.4 Objetos Básicos Definidos no Modelo Computacional

Para o desenvolvimento do modelo computacional foram definidos quatro objetos básicos, apresentados na FIGURA 6.1, em conjunto com alguns objetos deles derivados. O sistema EDIMA possui, na sua estrutura, mais de meia centena de classes de objetos. Obviamente, a exposição de todas essas classes foge ao escopo do presente trabalho. Entretanto, as classes de objetos que são visíveis ao usuário, representadas na FIGURA 6.2, são, a seguir, brevemente comentadas, com a intenção de demonstrar a filosofia e as capacidades presentes no sistema.

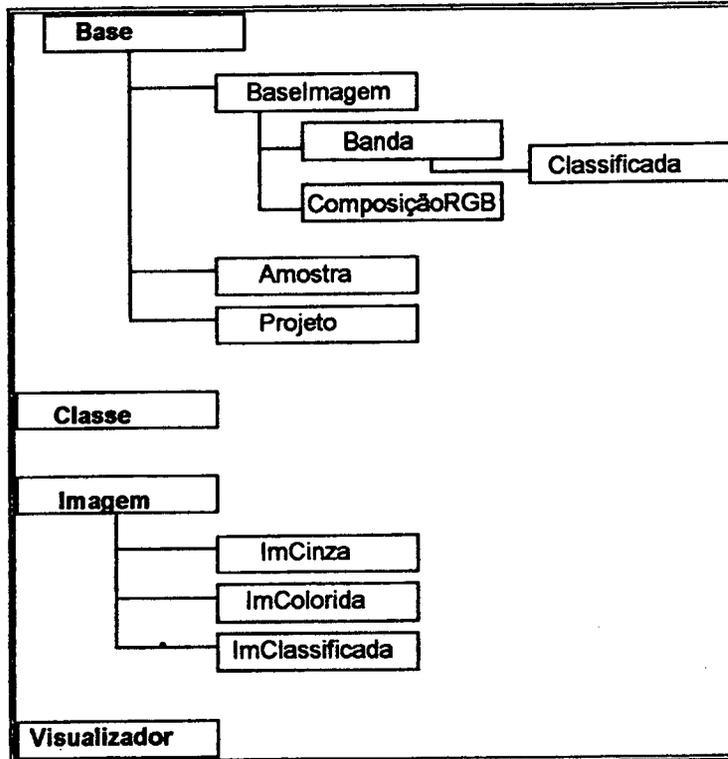


FIGURA 6.1 Objetos Básicos Definidos no Sistema EDIMA

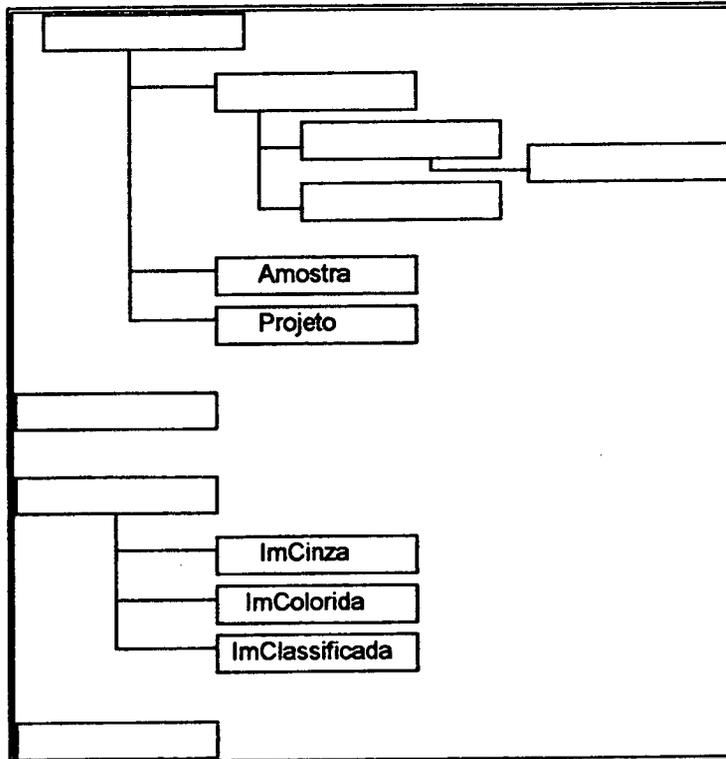


FIGURA 6.2 Objeto Visíveis ao Usuário

- Amostra: Consiste em duas janelas, uma mostrando as classes e a outra mostrando as áreas de treinamento numa composição colorida.

- **Projeto:** Consiste numa janela onde são listados e gerenciados todos os arquivos de uma determinada aplicação.

- **ImCinza:** Consiste numa "janela" contendo uma imagem com níveis de cinza variando entre 0 e 255. O objeto ImCinza pode representar uma banda espectral de uma imagem digital ou graus de pertinência de uma determinada classe em cada um dos pixels de uma dada imagem.

- **ImColorida:** Consiste numa "janela" contendo uma composição colorida de bandas espectrais associadas, respectivamente, aos canais Vermelho, Verde e Azul do sistema RGB.

- **ImClassificada:** Consiste numa "janela" contendo a representação de classes associadas a cada um dos pixels de uma imagem digital.

6.2.5 Sistema EDIMA: Uma Visão Global

O sistema EDIMA está organizado, do ponto de vista operacional, como um sistema de interface para diferentes documentos: bandas, composições coloridas, imagens classificadas, etc. O sistema foi projetado de forma a ser possível a aplicação de diferentes algoritmos sobre documentos gerenciados pelo sistema.

Para que seja processada uma sessão de trabalho, inicialmente é necessário que o usuário defina um projeto, a exemplo de ambientes de programação tradicionais, como IDE Interactive Development Environment, da Borland. A utilização dessa filosofia facilita a operação do sistema. Através dela, é possível agrupar todas as informações relevantes de um trabalho em um único projeto. O projeto permite gerenciar essas informações de forma extremamente amigável. Apesar de um projeto agrupar informações relevantes para uma sessão específica de trabalho, o usuário pode dispor, por exemplo, de uma mesma imagem (ou banda, ou amostra, etc.) em projetos diferentes, tornando, assim, o conceito de projeto um conceito apenas lógico. Essa propriedade tem o aspecto extremamente interessante de evitar a duplicidade de informações, resultando em economia, em termos de áreas de armazenamento.

O ambiente do projeto (FIGURA 6.3) permite manipular informações mostradas em janelas (*pop-up windows*) contendo:

- bandas espectrais de diferentes imagens;
- composições coloridas de bandas espectrais;
- imagens classificadas;
- conjunto de pixels agrupados por classes, nas áreas de treinamento definidas pelo usuário, e sua localização numa composição colorida;
- pertinências de classes em cada um dos pixels de uma imagem digital;
- presença de uma determinada classe em cada um dos pixels da imagem.

Essas janelas são gerenciadas de acordo com a filosofia do ambiente Windows, herdando deste todas as suas características (FIGURA 6.4).

No ambiente do EDIMA, as janelas do tipo *Banda* (FIGURA 6.5) permitem visualizar as diferentes bandas espectrais de imagens digitais. Note-se, aqui, que o sistema EDIMA permite a visualização simultânea de várias bandas espectrais de imagens diferentes. A limitação no número de bandas e imagens utilizadas está associada às dimensões do monitor disponível. Essa propriedade se estende aos demais tipos de janelas definidos.

As janelas do tipo "*Composição*" (FIGURA 6.6) permitem a visualização de composições coloridas definidas a partir de bandas espectrais de uma imagem digital.

A janela do tipo "*Amostra*" apresenta as diferentes áreas de treinamento, agrupadas por classes, e o número de pixels amostrados em cada área. Associada a essa janela, numa composição colorida, os elementos amostrados são assinalados (FIGURAS 6.7 e 6.8).

Projeto: JOINVI		
Nome	Tipo	Localização
ele2.amo	Amostra	.
ele1.amo	Amostra	.
ile_3f.ban	Banda	.
ilepp_3.ban	Banda	.
ile_3.ban	Banda	.
liepp_2f.ban	Banda	.
liepp_2.ban	Banda	.
ile_2.ban	Banda	.
ilepp_1f.ban	Banda	.
ilepp_1.ban	Banda	.

FIGURA 6.3 - Ambiente do Projeto

The screenshot shows the EDIMA software interface. The main window displays a satellite image of a landscape with a red overlay. A smaller window shows a zoomed-in view of a specific area. The interface includes a menu bar, a toolbar, and a status bar.

Amostra: ELE2 - 5273 pixels
III-4 112
pasto [585]

Nome	Tipo
ilepp321	
ele2.amo	Amostra
ele1.amo	Amostra
ile_3f.ban	Banda
ilepp_3.ban	Banda

FIGURA 6.4 - Exemplos de Janelas de Um Projeto

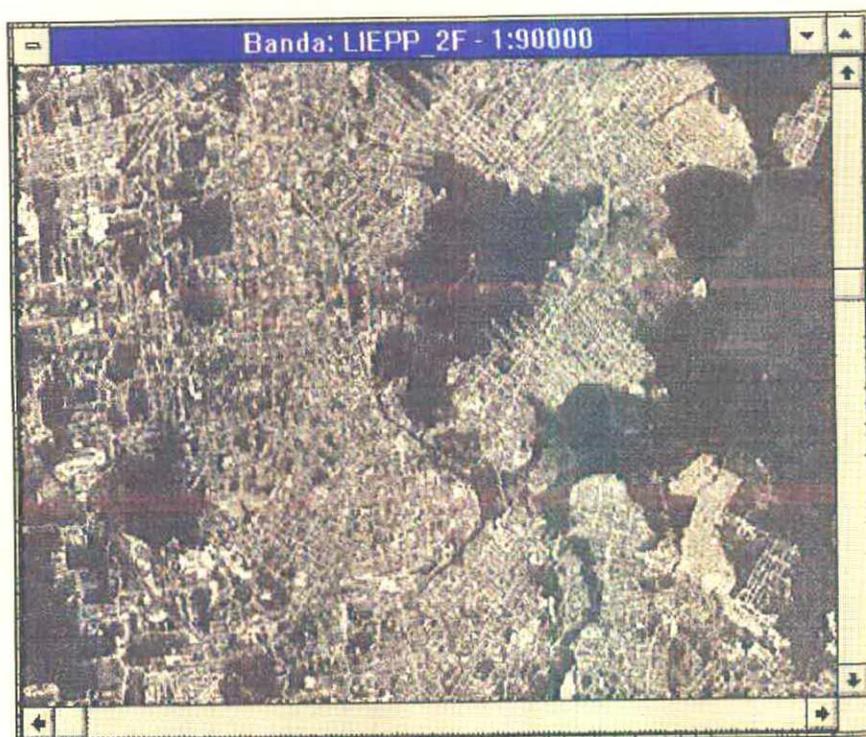


FIGURA 6.5 - Janela do Tipo Banda

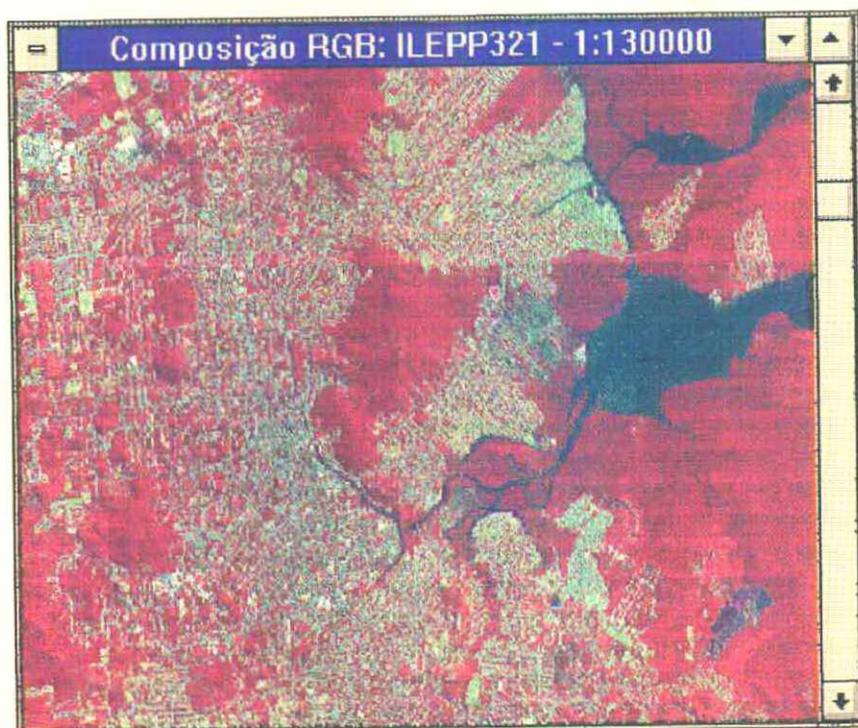


FIGURA 6.6 - Composição Colorida

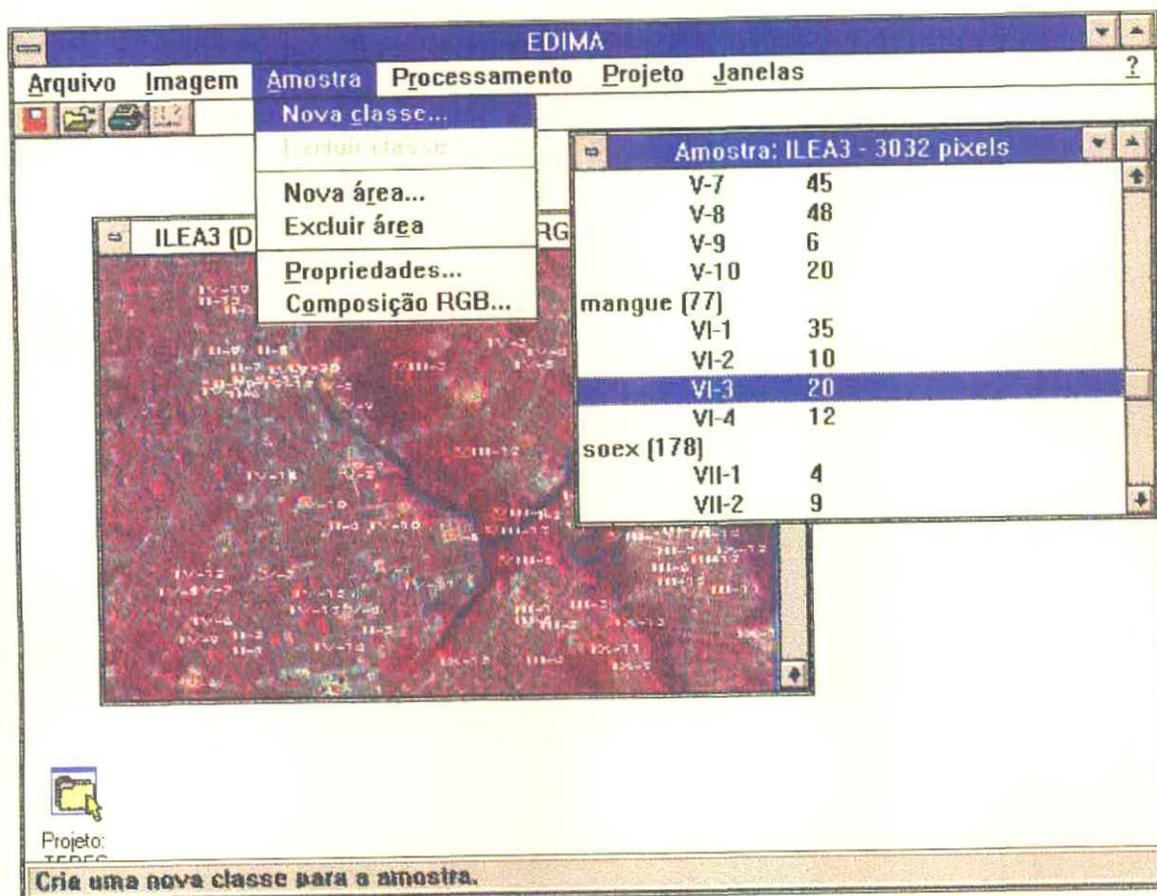


FIGURA 6.7 - Obtenção de Amostras

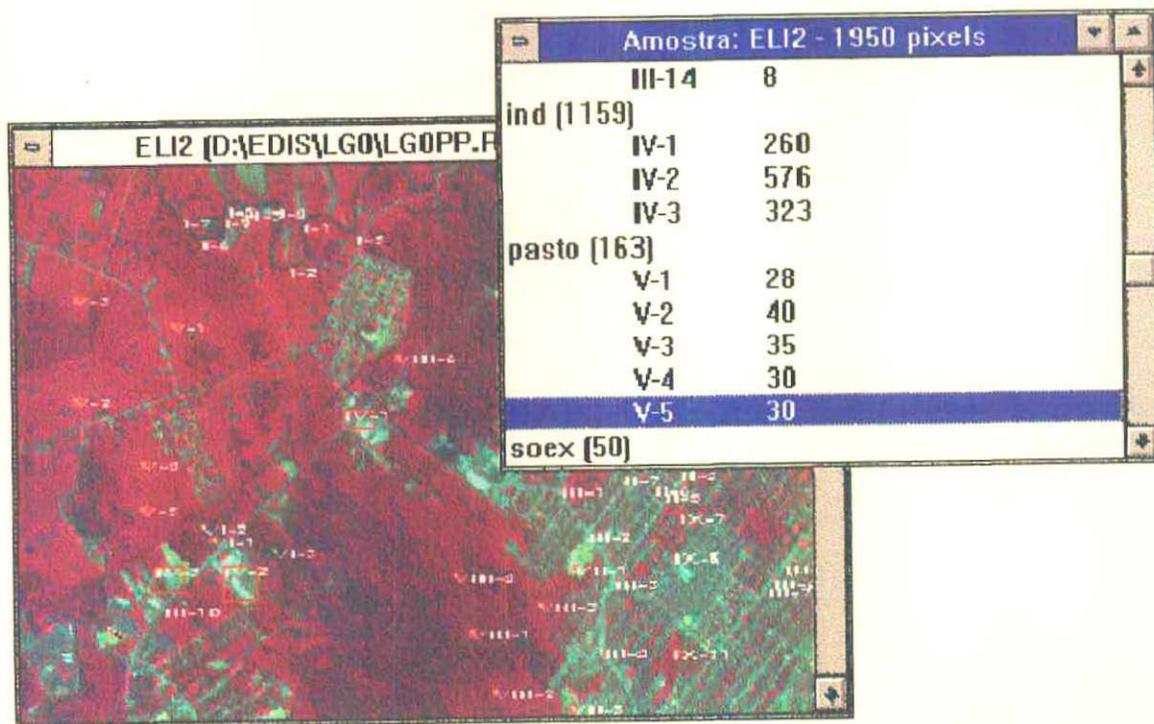


FIGURA 6.8 - Localização das Amostras

Janelas do tipo "*Classificada*" apresentam o resultado da aplicação de um processo de classificação sobre uma imagem digital. A janela mostra, no lado esquerdo, a imagem classificada de acordo com as classes definidas pelo usuário. O nome das diferentes classes assim como a codificação das cores adotada são apresentadas à direita (FIGURA 6.9).

As pertinências de uma classe, em cada um dos pixels, podem ser visualizadas numa janela do tipo "*Banda*". Para designar o grau de pertinência obtido, é utilizada uma escala de níveis de cinza, que varia de 0 a 255. Os valores de níveis de cinza 0 e 255 representam, respectivamente, pertinência 0 e pertinência 1 (equivalendo, em termos de cores, a preto e branco). A presença de uma determinada classe em um pixel pode, também, ser visualizada em uma janela do tipo "*Banda*". Nesse caso, a cor branca denota que, para o pixel correspondente, aquela classe está presente. A FIGURA 6.10 exemplifica esse caso.

O ambiente do projeto permite acessar diferentes funções e algoritmos para pré-processamento, processamento, pós-processamento, etc., de acordo com o tipo de janela em foco (ativa).

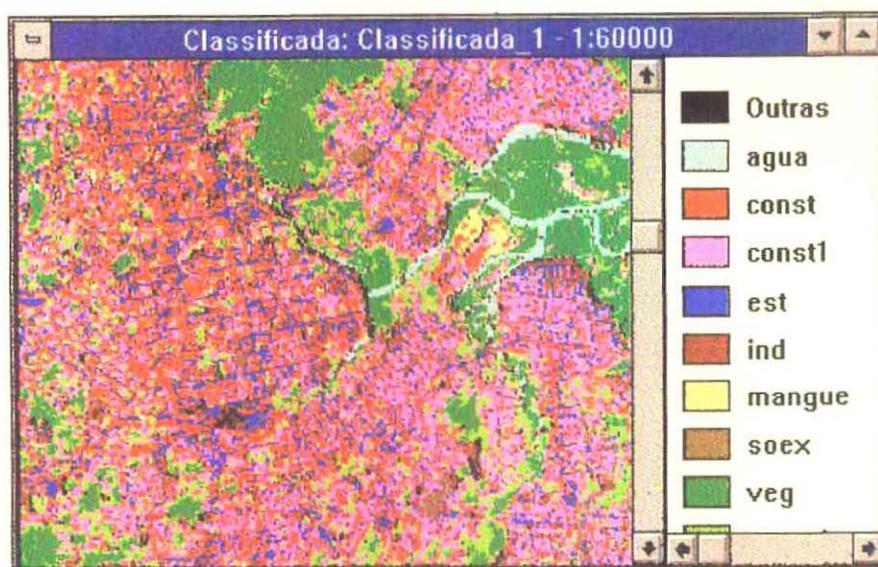


FIGURA 6.9 - Imagem Classificada



FIGURA 6.10 -.Imagem de Pertinência

6.3 Algoritmos e Funções Implementados

Os algoritmos e funções disponíveis são agrupados da seguinte forma:

- *funções básicas* - conjunto de funções disponíveis para várias janelas e de caráter geral, tais como salvar, imprimir, etc.
- *funções de pré-processamento* - disponíveis para as janelas do tipo banda, incluem algoritmos para tratamento das bandas espectrais com vistas a melhorar as suas características.
- *funções de processamento* - as funções de processamento estão sempre disponíveis e permitem realizar classificação de imagens multiespectrais.
- *funções de pós-processamento* - permitem avaliar o resultado de um processo de classificação.

6.3.1 Funções Básicas

O grupo de funções básicas inclui funções gerais, tais como salvar, imprimir, configurar impressora, arrumar janelas, etc. (FIGURAS 6.11 e 6.12). Através da função *Novo*, é possível criar-se janelas de amostras, de composições coloridas, registros e imagens sintéticas (FIGURA 6.13).

O algoritmo para criação de uma imagem sintética foi implementado com o objetivo de permitir a análise do desempenho de diferentes classificadores. Inicialmente, é solicitado ao usuário o tamanho da imagem (em pixels), o tamanho de cada área e o número de classes (FIGURA 6.14). É criada uma imagem quadrada, dividida em áreas também quadradas, com tamanhos iguais aos informados. A seguir, são solicitadas informações sobre as distribuições de probabilidade dos níveis de cinza para cada classe, em três bandas (FIGURA 6.15). O algoritmo escolhe aleatoriamente, uma classe para cada área e os níveis de cinza nas três bandas, para cada um dos pixels.

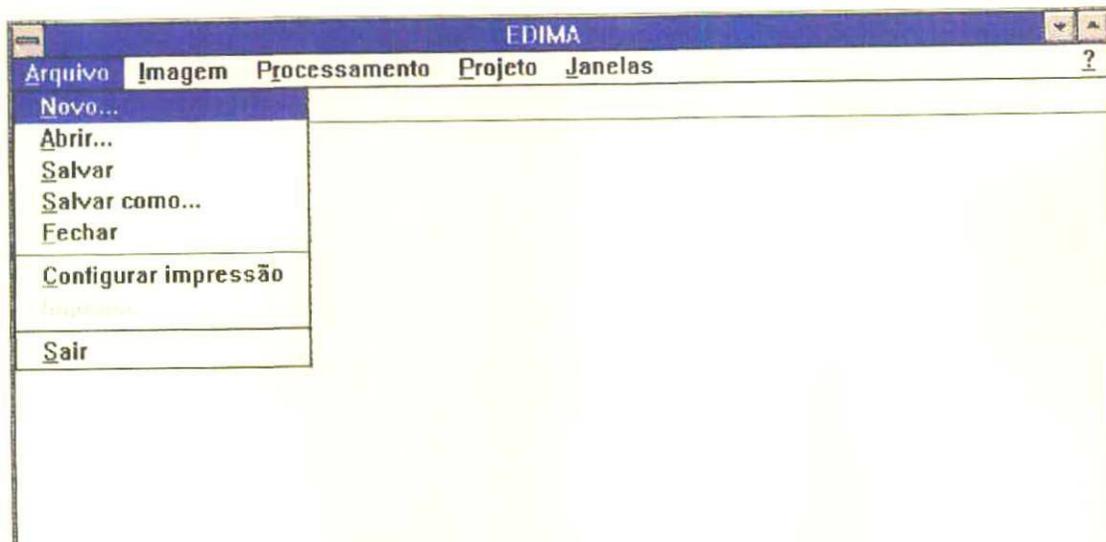


FIGURA 6.11 - Funções de Arquivo

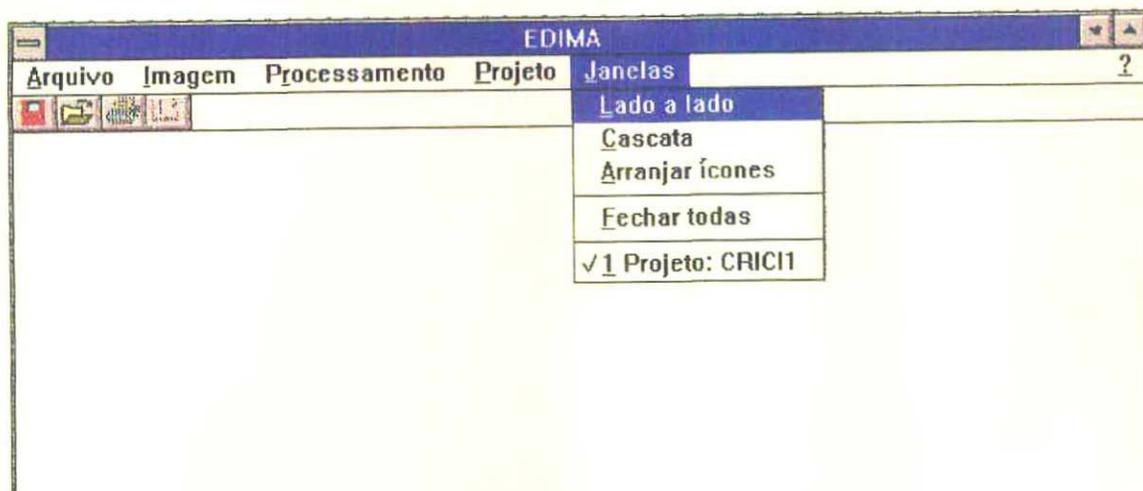


FIGURA 6.12 - Funções de Janelas

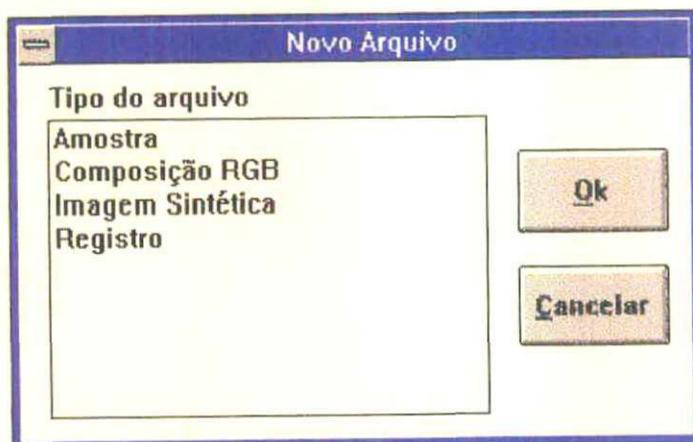


FIGURA 6.13 - Tipos de Arquivo da Função Novo

Dados para Imagem Sintética

Tamanho da Imagem: 64

Tamanho das Áreas: 1

Número de Classes: 3

Ok Cancelar

FIGURA 6.14 - Dados para a Imagem Sintética

Imagem Sintética - Classe 1

Médias das Bandas

	1	2	3
	<input type="text"/>	<input type="text"/>	<input type="text"/>

Covariâncias entre Bandas

	1	2	3
1	<input type="text"/>	<input type="text"/>	<input type="text"/>
2		<input type="text"/>	<input type="text"/>
3			<input type="text"/>

Anterior

Ok Cancelar

FIGURA 6.15 - Informações para Geração de uma Classe

Estão disponíveis também, para todas as janelas de imagens (bandas, composições coloridas, etc), as funções de mudança de escala, "zoom in" e "zoom out", mostrar coordenadas em termos de pixels e propriedades. No grupo propriedades, informações sobre resolução espacial, tamanho em pixels e metros da imagem estão acessíveis ao usuário. Além disso, comentários e anotações sobre as informações visualizadas na janela podem ser registrados e editados na janela de propriedades (FIGURA 6.16).

No conjunto de funções básicas, podem-se também incluir as funções de gerenciamento de projetos. Como anteriormente colocado, uma sessão de trabalho é gerenciada através do conceito de projeto. O projeto mantém, basicamente, informações sobre os arquivos disponíveis para aplicação dos diferentes algoritmos. Assim, é possível criar-se novos projetos e incluir arquivos em projetos. A estrutura de projetos permite abrir, para visualização, rapidamente os diferentes arquivos. Todos os algoritmos que necessitam de bandas ou outros tipos de arquivos utilizam aqueles constantes no projeto (FIGURA 6.17).

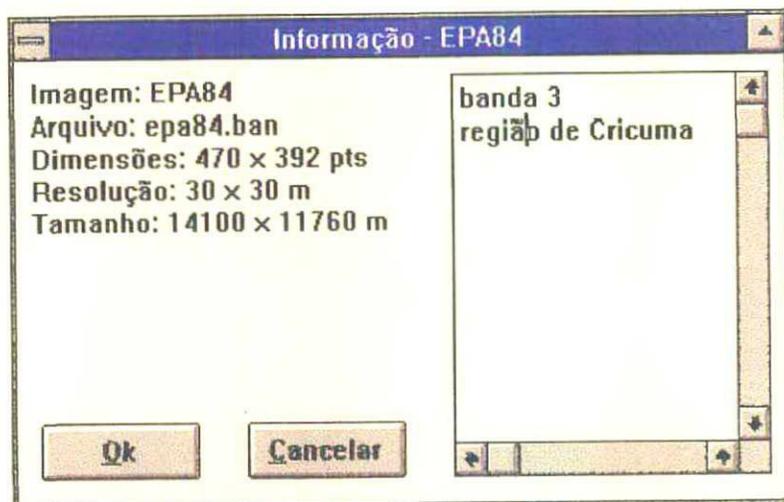


FIGURA 6.16 - Janela de Propriedades

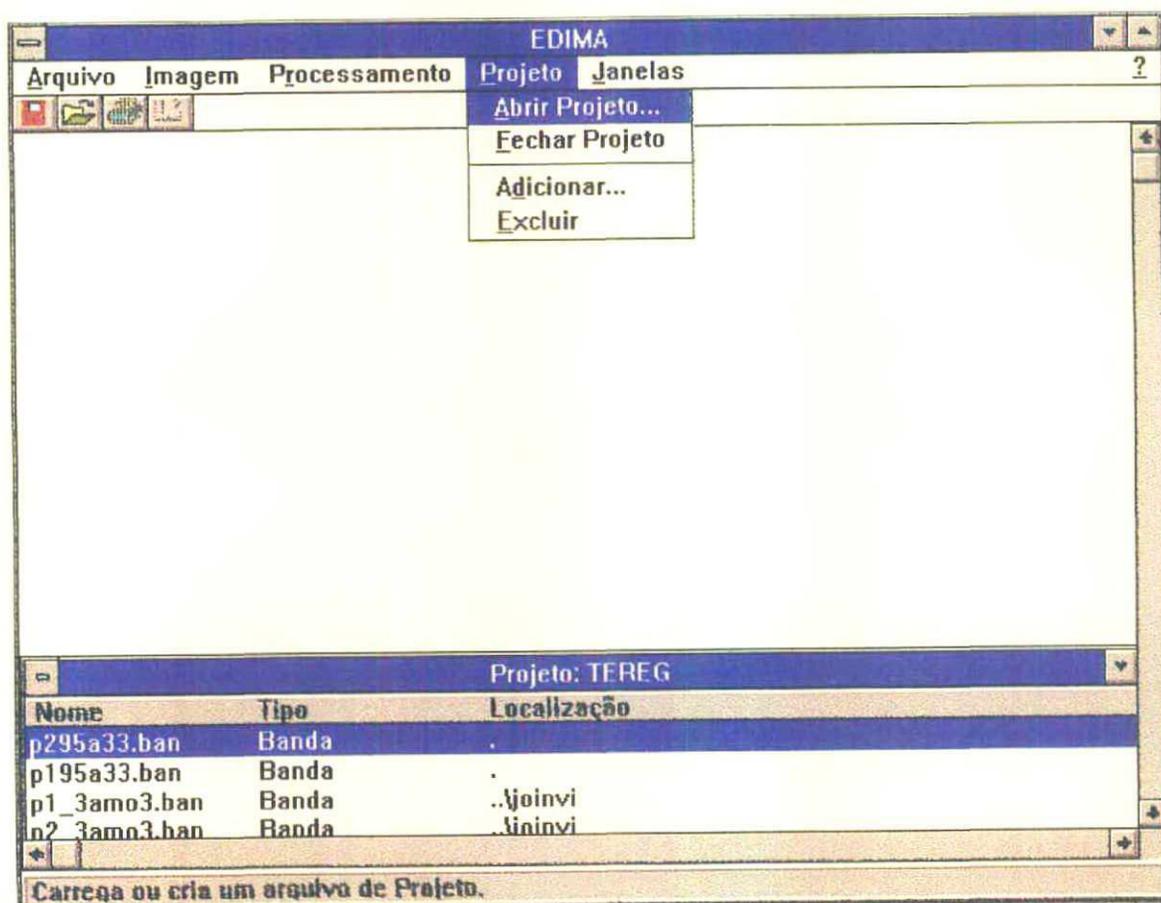


FIGURA 6.17 - Funções de Gerenciamento de Projeto

6.3.2 Funções de Preprocessamento

As funções de preprocessamento permitem aplicar algoritmos de tratamento sobre bandas espectrais de imagens digitais. Foram implementados e estão disponíveis:

Manipulação de Contraste por Transformação Linear e por Transformação Linear por Partes

A função de manipulação de contraste pode ser realizada através de uma ou várias transformações lineares dos níveis de cinza (FIGURA 6.18).

No caso de uma única transformação linear, os novos níveis de cinza (mínimo e máximo) são solicitados ao usuário. (FIGURA 6.19). Na transformação linear por partes, devem ser dados os níveis de cinza atuais e os novos valores para os intervalos de transformação desejados (FIGURA 6.20). Nas duas opções, após executar o algoritmo, uma nova janela é aberta, mostrando o resultado da manipulação de contraste.

Filtragem Espacial

A filtragem espacial consiste na transformação que leva em consideração os valores dos níveis de cinza da vizinhança de cada pixel. Para a realização dessa operação, uma máscara é aplicada sobre a imagem. Estão disponíveis quatro tamanhos de máscaras (3x3, 5x5, 7x7 e 9x9)(FIGURA 6.21), as quais podem ser gravadas em arquivos do tipo texto, para posterior utilização. Uma vez definida a máscara (FIGURA 6.22), o algoritmo de filtragem é aplicado, fornecendo uma nova janela com a banda filtrada (FIGURA 6.23).

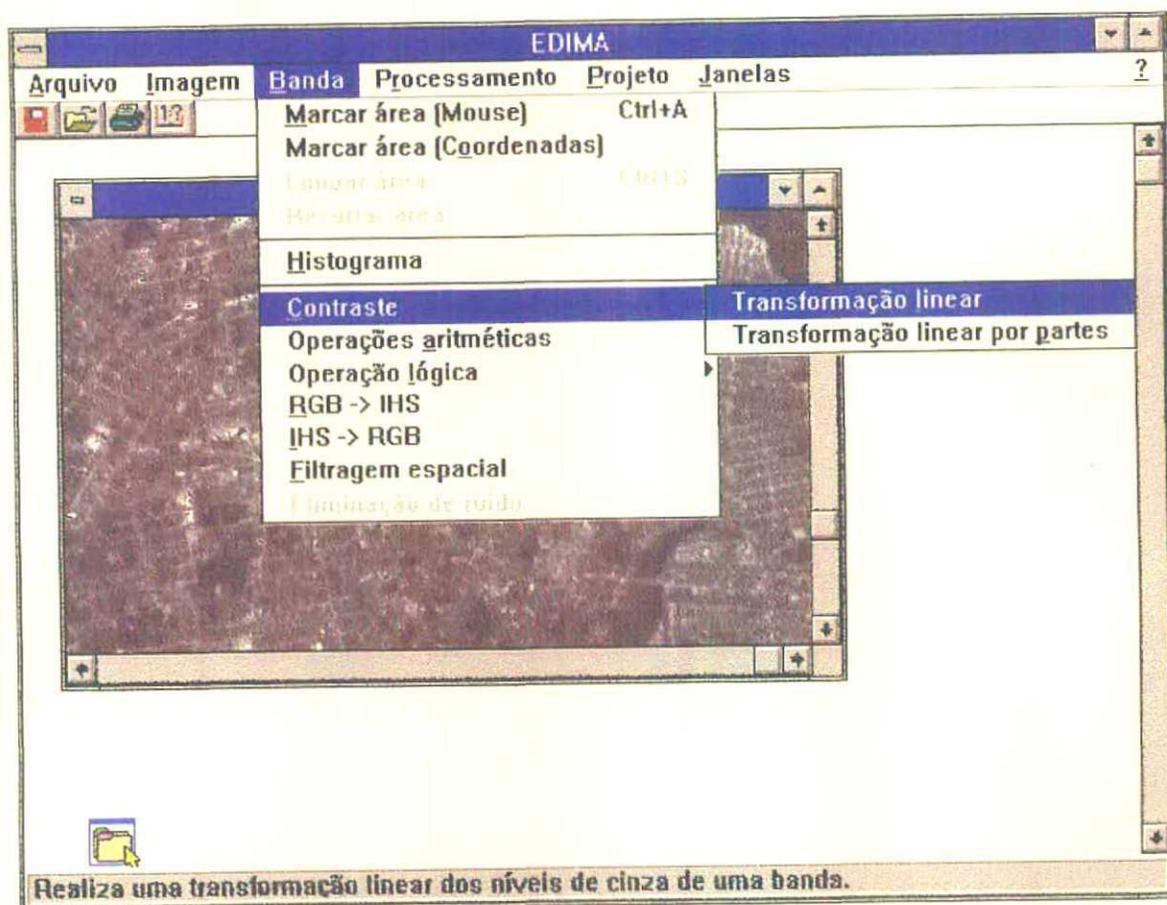


FIGURA 6.18 - Função de Manipulação de Contraste

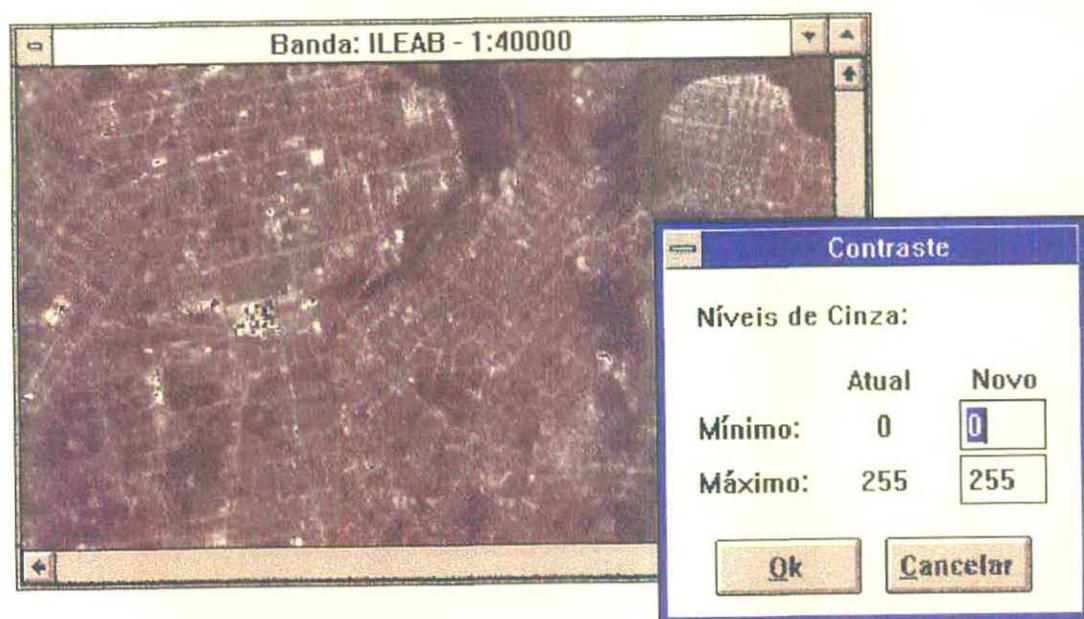


FIGURA 6.19 - Transformação Linear

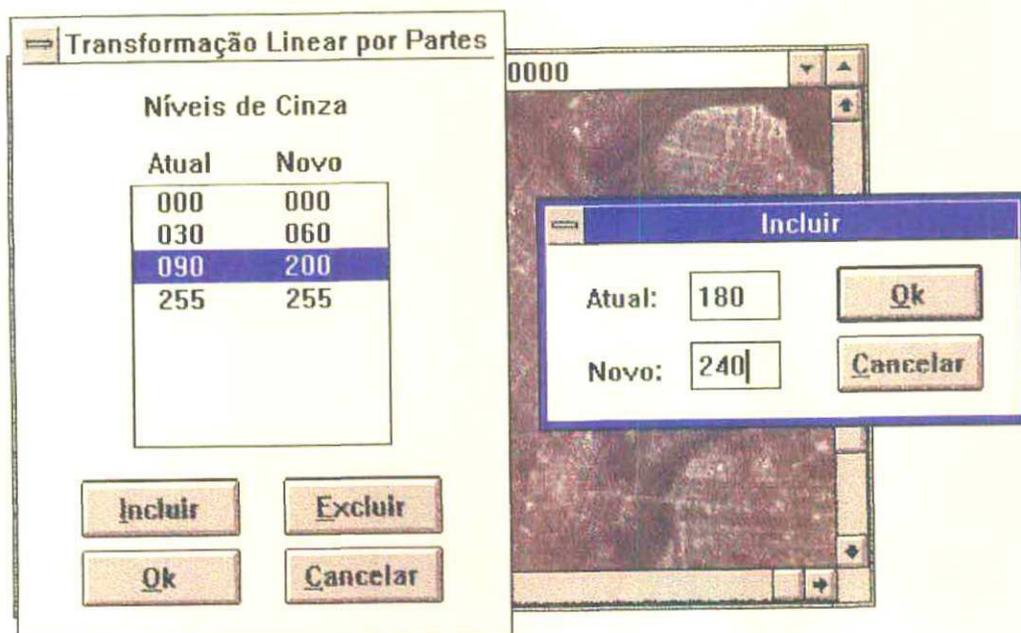


FIGURA 6.20 - Transformação Linear por Partes



FIGURA 6.21 - Tamanhos de Máscara Disponíveis

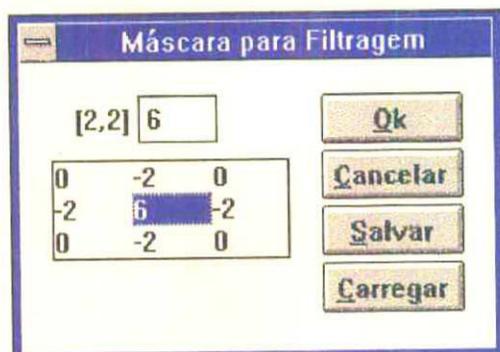


FIGURA 6.22 - Exemplo de Máscara 3x3

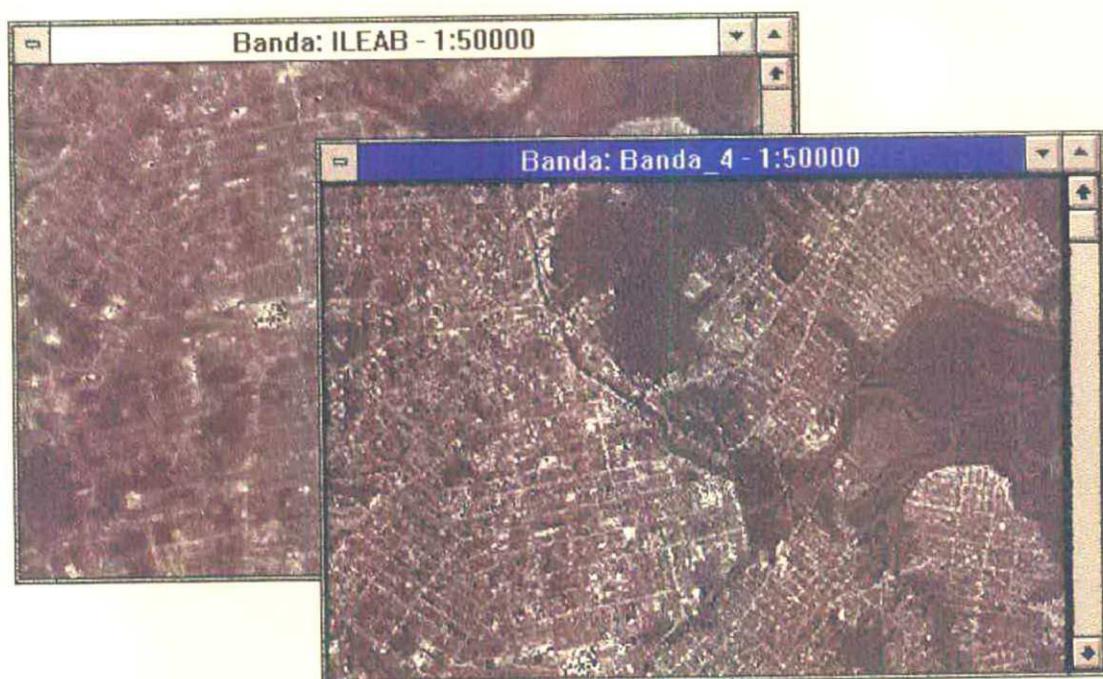


FIGURA 6.23 - Banda Filtrada

Registro Imagem-Imagem

O sistema permite a realização do registro imagem-imagem. Os dados do registro são manipulados através de um objeto específico. Esse objeto pode ser gravado como arquivo e carregado quando necessário. O registro é executado marcando-se pontos em duas bandas, que são visualizadas simultaneamente em uma janela. Em outra janela, as coordenadas dos pontos e os erros são mostrados (FIGURA 6.24).

Marcar Áreas

Nas janelas de banda, é possível delimitar uma área retangular. Essa área é utilizada, por exemplo, na eliminação de ruído, como perímetro de corte para trabalhar com parte da imagem, etc. (FIGURA 6.25).

Histograma dos Níveis de Cinza

Com o objetivo de observar o comportamento espectral das bandas, está disponível uma função que constrói o histograma dos níveis de cinza de uma banda ou de uma área da banda (FIGURA 6.26).

Recorte de Áreas

A partir de uma banda, pode ser obtida uma área menor, através do recorte de um retângulo (FIGURA 6.27).

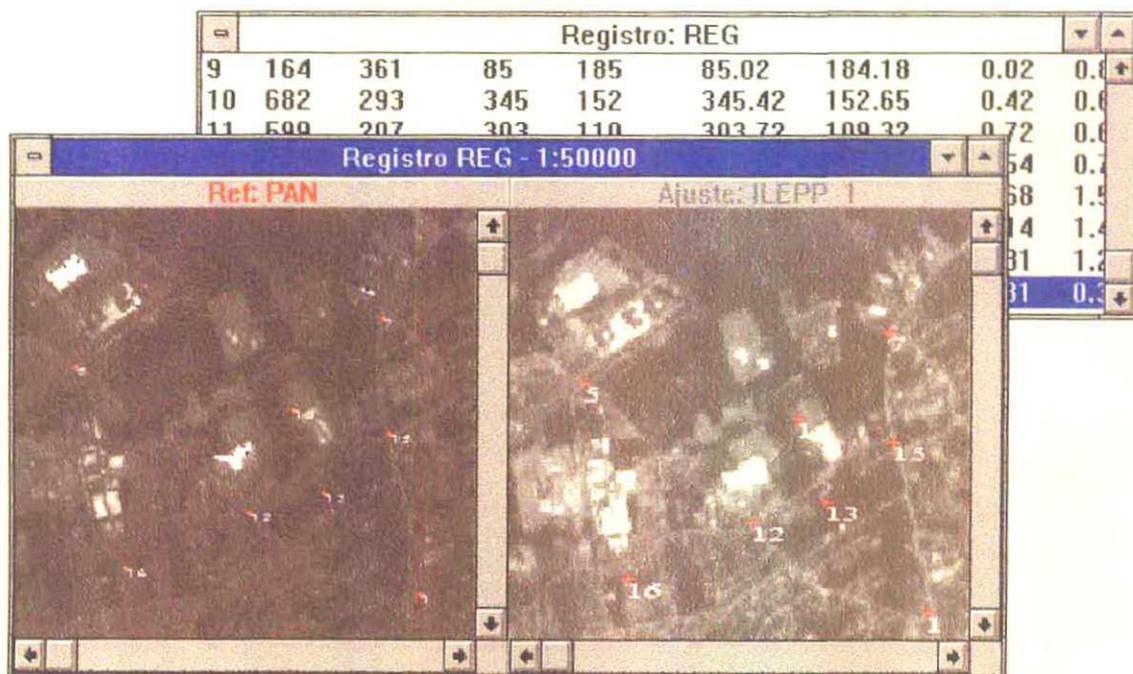


FIGURA 6.24 - Janela de Registro Contendo Duas Bandas e Janela com Dados dos Pontos



FIGURA 6.25- Delimitação de Área

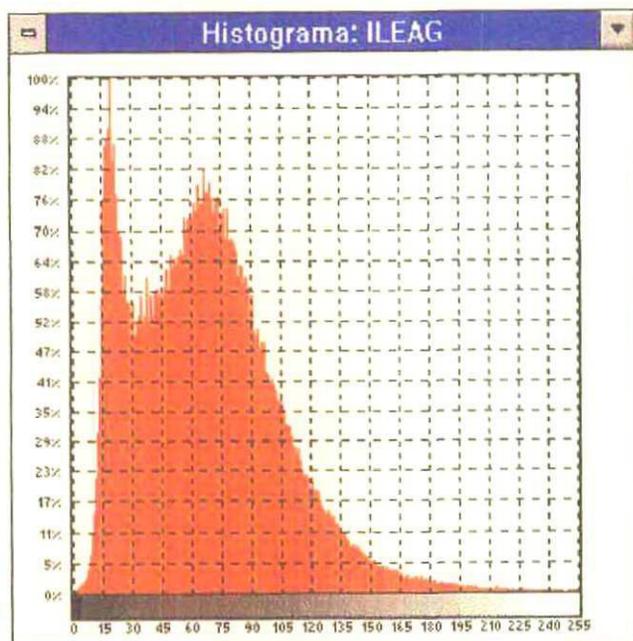


FIGURA 6.26 - Histograma de uma Banda

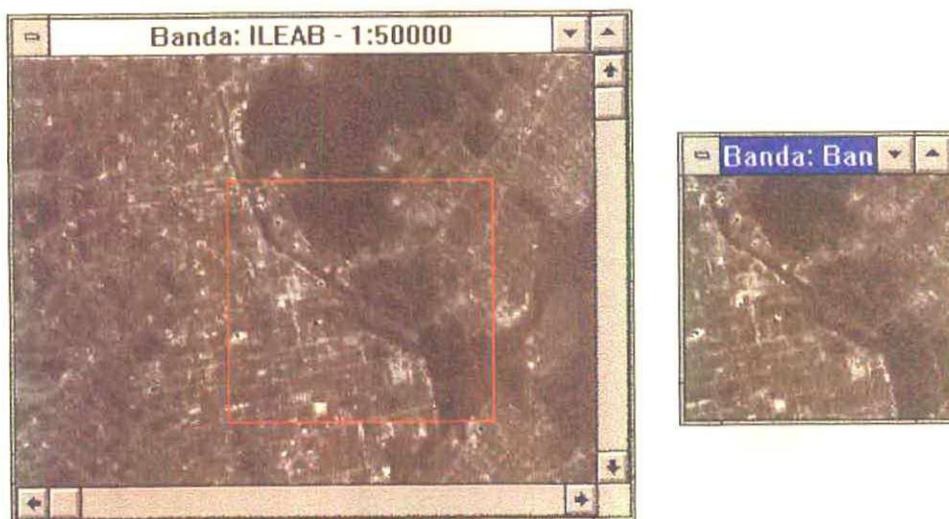


FIGURA 6.27 - Recorte de Área

Operações Aritméticas e Operações Lógicas

No pré-processamento, é possível realizar operações aritméticas e lógicas com os níveis de cinza de uma banda. No EDIMA, encontram-se implementados a subtração do valor mínimo de todos os níveis de cinza da banda, máximo e mínimo relativos a duas bandas (FIGURA 6.28).

Eliminação de Ruído

Eliminação de ruído visa eliminar possíveis distorções existentes na imagem provenientes, principalmente, de falhas dos detectores durante o imageamento.

Transformações RGB/IHS e IHS/RGB

A transformação RGB/IHS atribui três bandas aos canais R (vermelho), G (verde) e B (azul) respectivamente, para obter a intensidade (I), a matiz (H) e a saturação (S). Na FIGURA 6.29, é apresentada a janela de interface para associação de bandas aos canais.

A transformação (IHS/RGB) realiza a operação inversa da descrita anteriormente. Nessa operação, o sistema questiona ao usuário as bandas a serem utilizadas, em interface semelhante à transformação RGB/IHS.

6.3.3 Funções de Processamento

Os algoritmos de classificação implementados foram o algoritmo de máxima verosimilhança e um algoritmo de classificação difusa baseado no algoritmo de máxima verosimilhança.

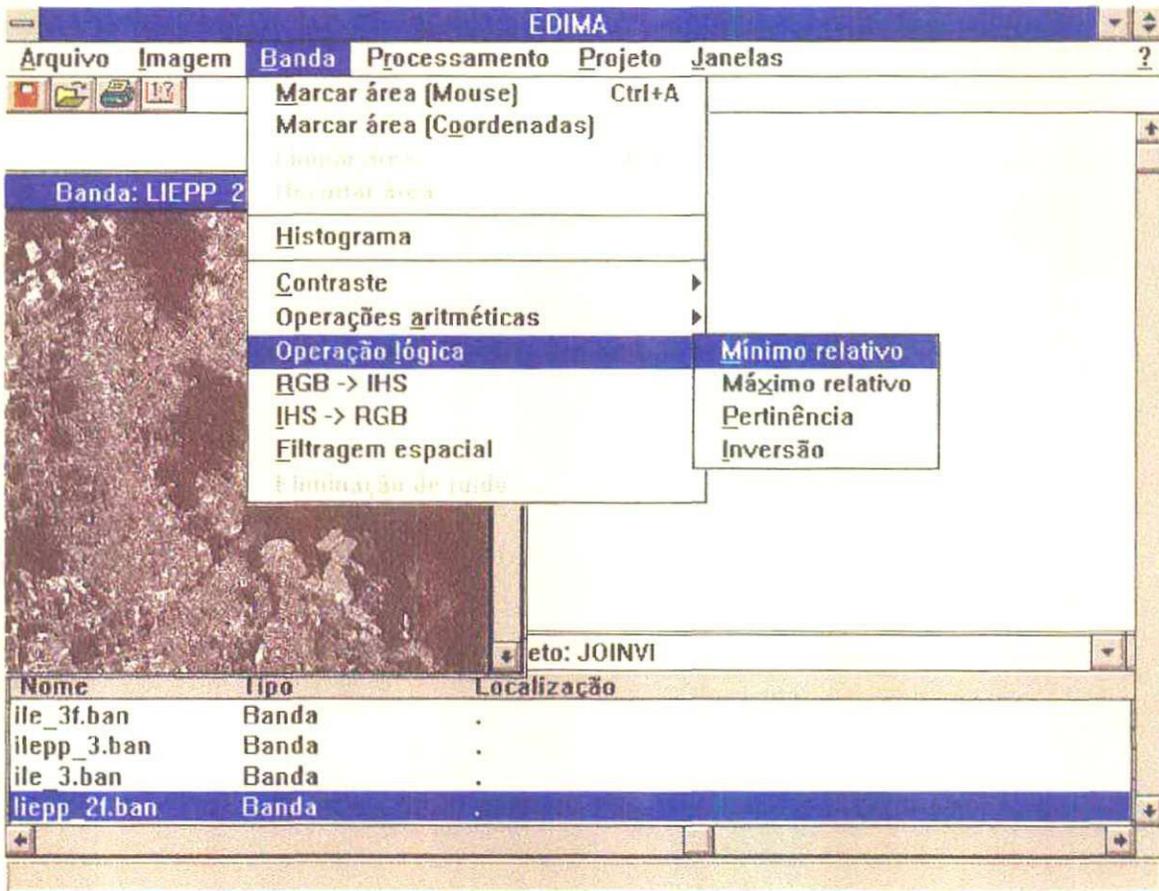


FIGURA 6.28 - Operações Lógicas

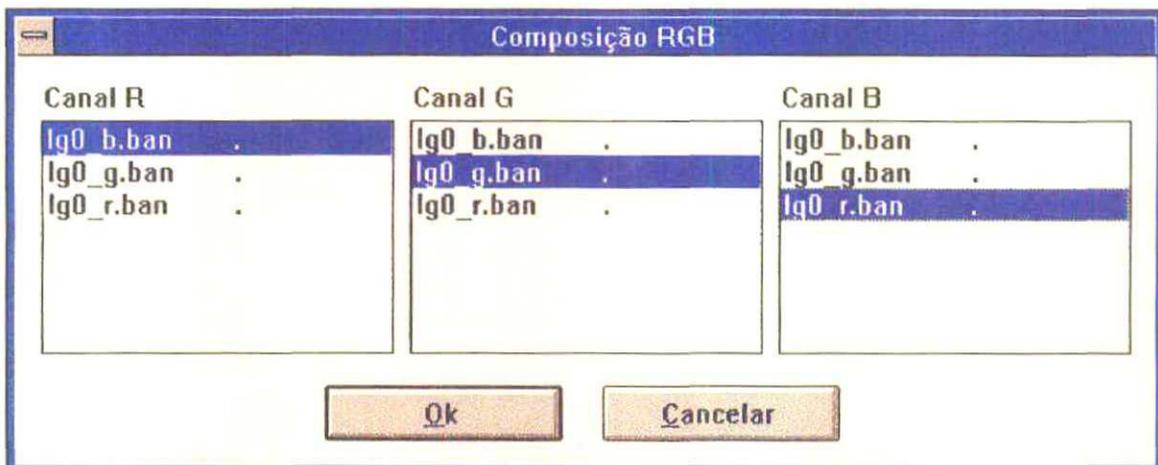


FIGURA 6.29 - Interface da Transformação RGB/IHS

Classificação por Máxima Verossimilhança

Consiste na implementação do tradicional algoritmo baseado na função de verossimilhança. O sistema EDIMA permite trabalhar com um número de bandas variando entre três e sete. Os níveis de confiança implementados são 75, 95, 99 e 99.5%. Na sua aplicação, o usuário é questionado sobre o nome do arquivo que contém as coordenadas das áreas de treinamento (também chamado de arquivo de amostra (FIGURA 6.30)). A seguir, deve-se informar as bandas que entrarão no processo de classificação (FIGURA 6.31) e o nível de confiança a ser utilizado.

Como resultado da aplicação do algoritmo, o sistema fornece uma janela com a imagem classificada (FIGURA 6.32).

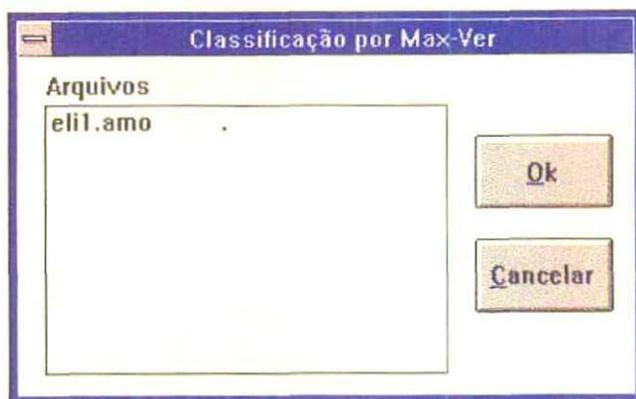


FIGURA 6.30 - Arquivos de Amostras

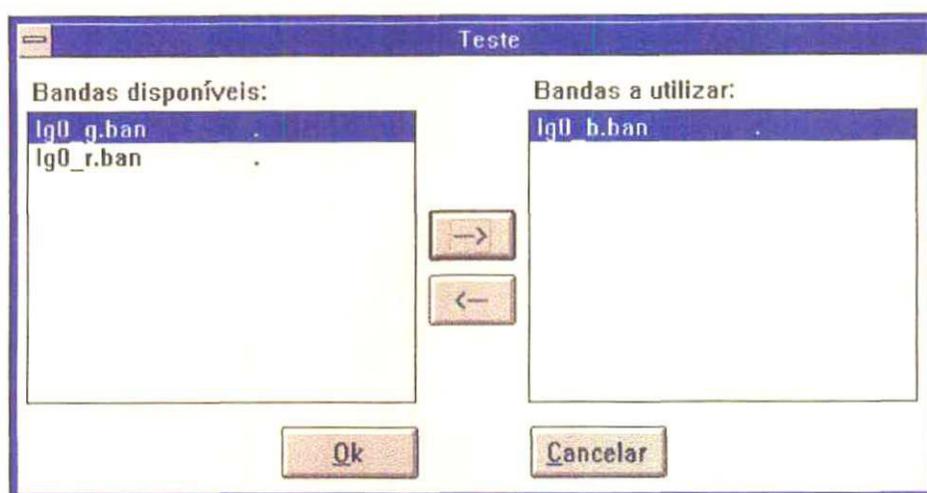


FIGURA 6.31 - Escolha das Bandas para o Processo de Classificação

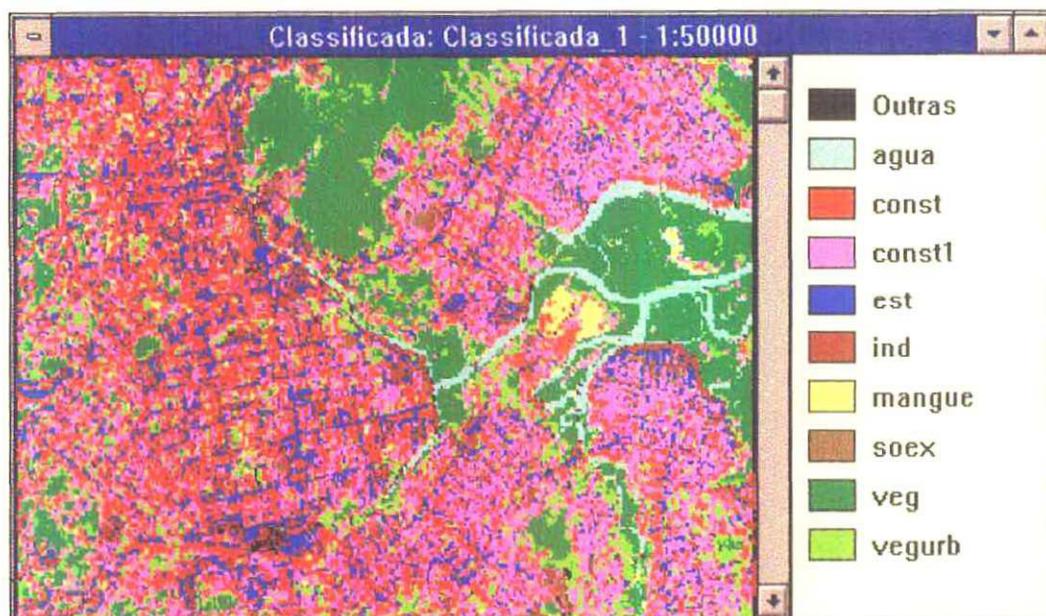


FIGURA 6.32 - Imagem Classificada - Máxima Verossimilhança

Classificação Utilizando Conjuntos Difusos

O classificador difuso implementado foi apresentado no capítulo 5 e o seu resultado constitui-se em uma partição difusa do espaço das classes em cada pixel. Diversas informações podem ser obtidas a partir desse classificador (FIGURA 6.33):

- as pertinências de cada classe em cada um dos pixels das imagens visualizadas em janelas do tipo banda, onde o nível de cinza representa essa pertinência (FIGURA 6.34);
- cortes de nível alfa, apresentando a imagem classificada com pertinência maior ou igual ao nível especificado. Na imagem classificada, reserva-se a cor branca para pixels que apresentam misturas de classes (FIGURA 6.35);
- a área de cada classe, aos diferentes níveis de pertinência (FIGURA 6.36);
- a similaridade do contexto de cada pixel da imagem a um determinado padrão (FIGURA 6.37);
- padrões de metaclasses (FIGURA 6.38).

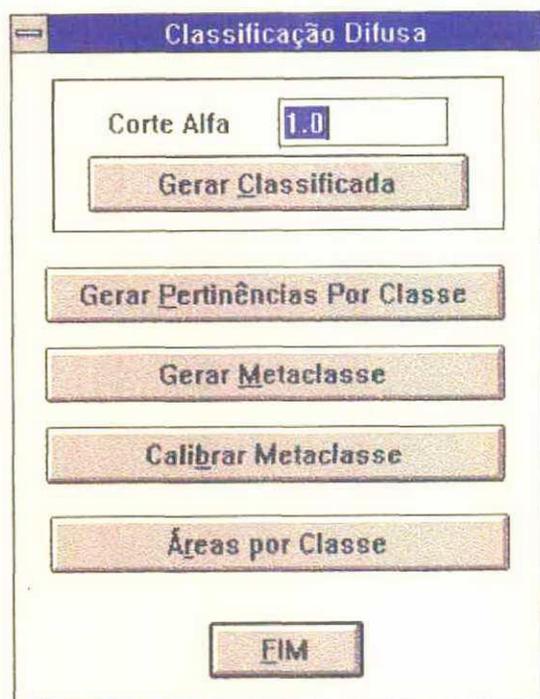


FIGURA 6.33 - Interface de Gerenciamento do Classificador Difuso

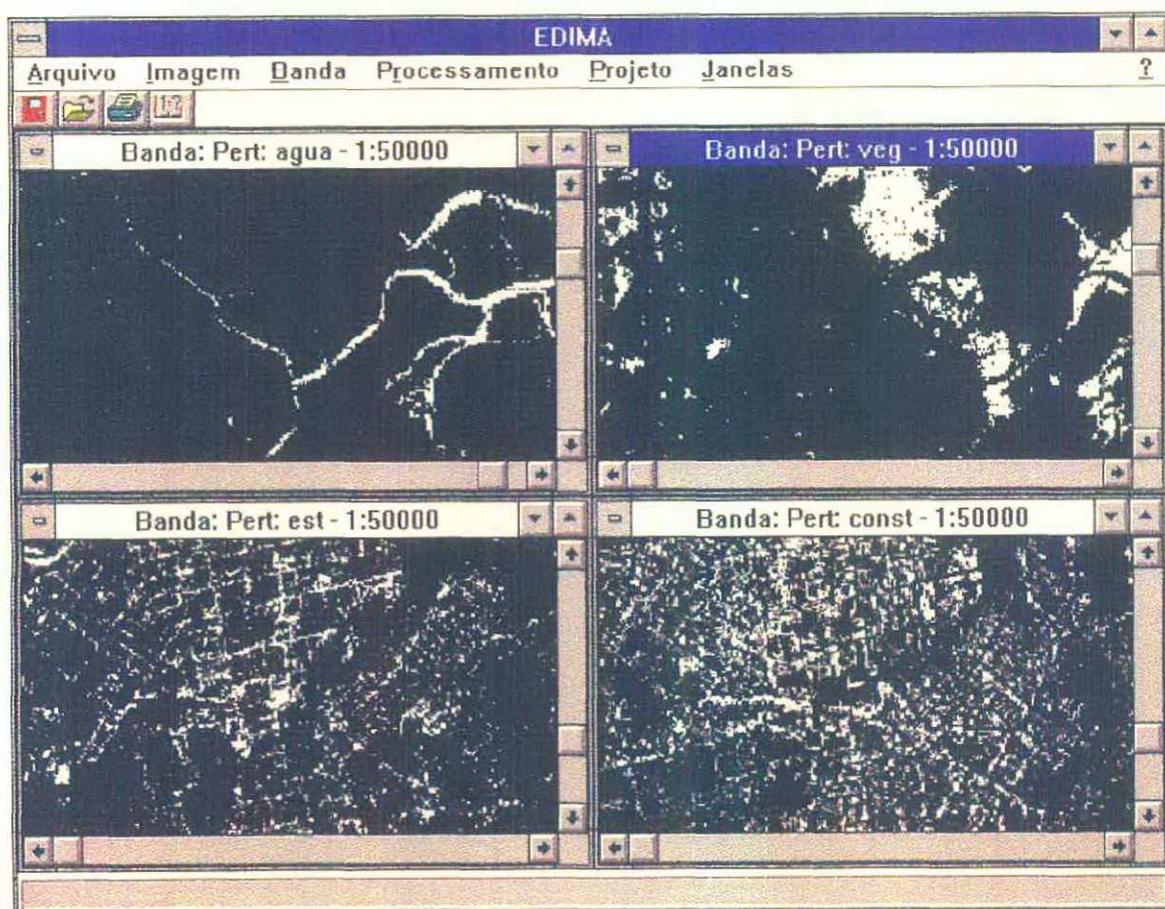


FIGURA 6.34 - Imagem de Pertinência

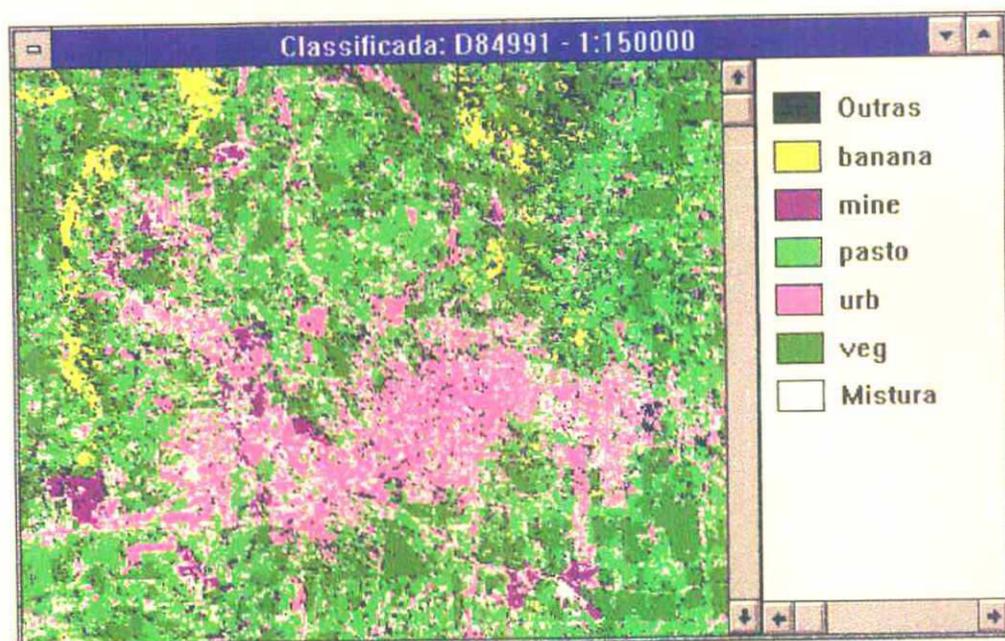


FIGURA 6.35 - Imagem Classificada - Classificador Difuso

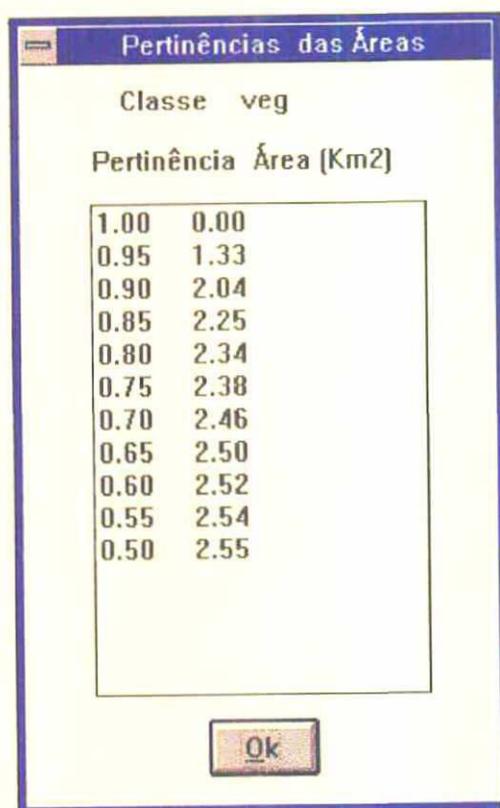


FIGURA 6.36 - Áreas de uma Classe aos Diferentes Níveis de Pertinência

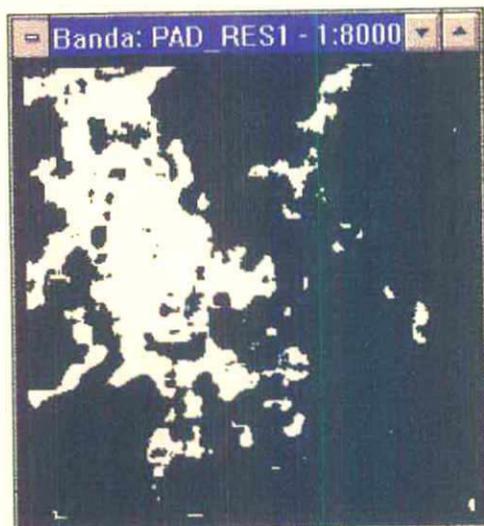


FIGURA 6.37 - Similaridade a um Padrão

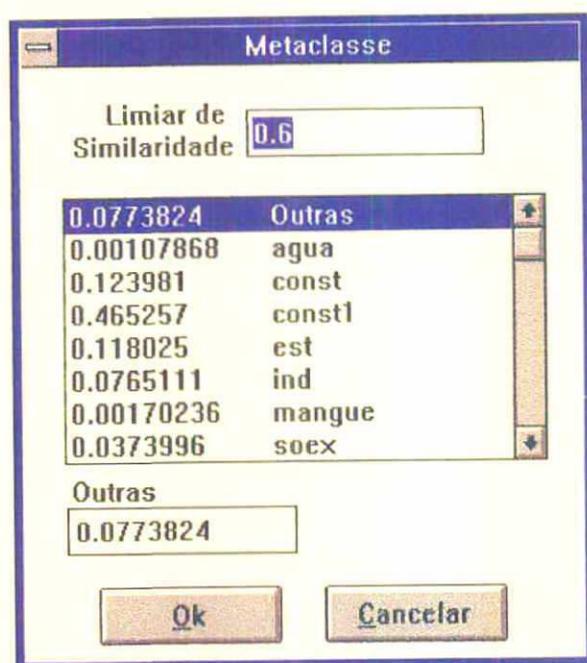


FIGURA 6.38 - Padrão de Uma Metaclassa

6.3.4 Funções de Posprocessamento

Uniformização de Temas

Uma das funções de posprocessamento implementadas é a uniformização de temas, na qual é realizada a reatribuição de um pixel a outra classe, em função do seu contexto. O sistema solicita ao usuário um limiar e um peso (FIGURA 6.39). O resultado da aplicação dessa função é uma nova imagem classificada (FIGURA 6.40).

Análise de Desempenho da Amostra

A função análise de desempenho permite calcular o desempenho dos classificadores. Para tanto, os resultados apresentados numa imagem classificada são comparados com as informações gravadas numa amostra. A amostra pode ser a mesma utilizada para treinar o classificador, ou outra diferente. Como resultado, é apresentada uma matriz na qual os pixels são comparados classe a classe (FIGURA 6.41). É possível obter-se também o desempenho de cada área de treinamento de uma classe (FIGURA 6.42).

Coeficiente Kappa

O sistema permite calcular o coeficiente Kappa (BISHOP, FIENBEG e HOLLAND (1988) e GONG e HOWARTH (1992)). Este coeficiente está disponível para avaliar o resultado de uma classificação ou para comparar-se os resultados de duas classificações realizadas sobre uma imagem. (FIGURAS 6.43 e 6.44). Além do coeficiente global, são também calculados os valores condicionais desse coeficiente (grau de concordância para uma única classe).

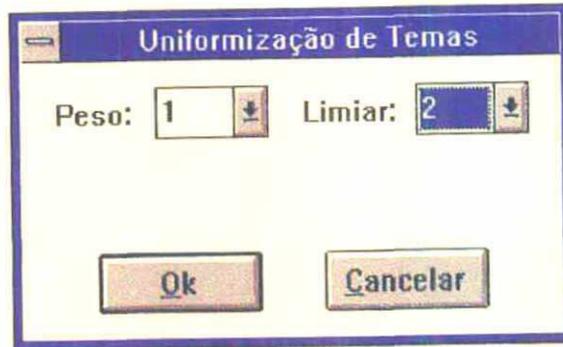


FIGURA 6.39 - Limiar e Peso Solicitado ao Usuário

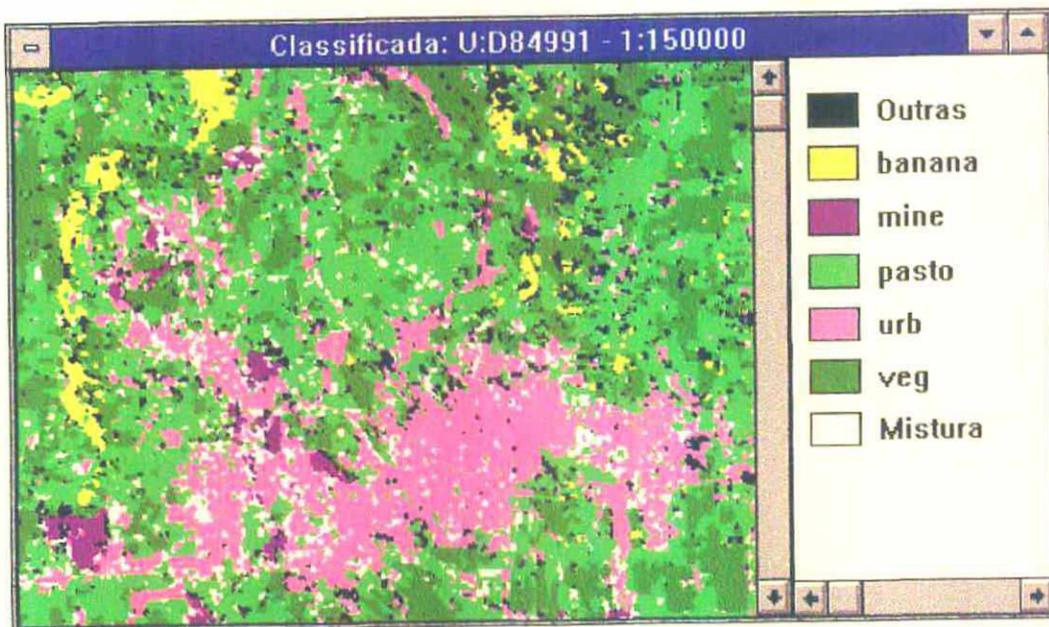


FIGURA 6.40 - Imagem Classificada com Uniformização de Temas

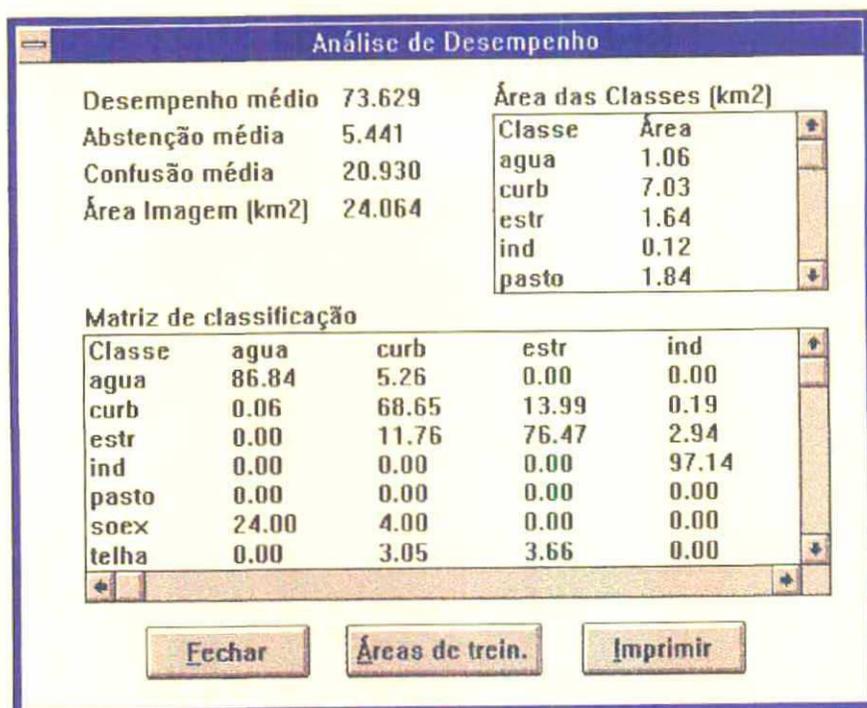


FIGURA 6.41 - Desempenho das Diferentes Classes

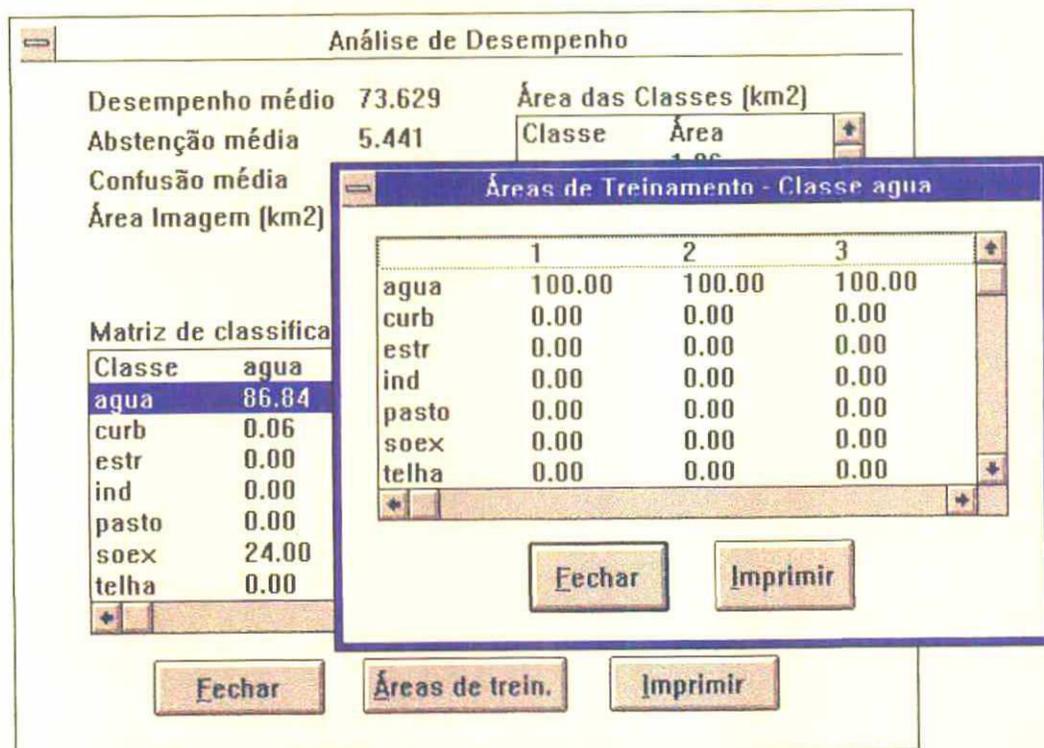


FIGURA 6.42 - Desempenho das Diferentes Áreas de Treinamento de uma Classe

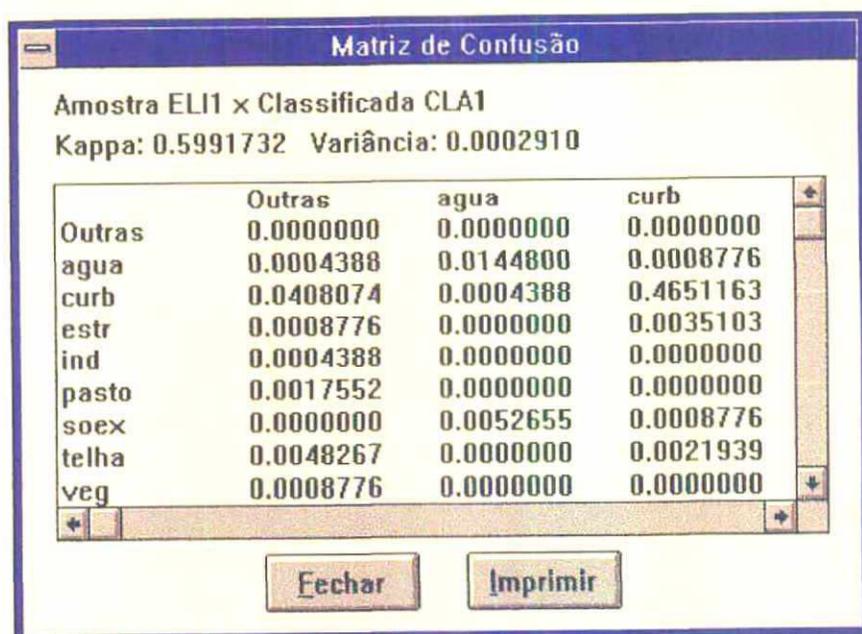


FIGURA 6.43 - Coeficiente Kappa para uma Classificação

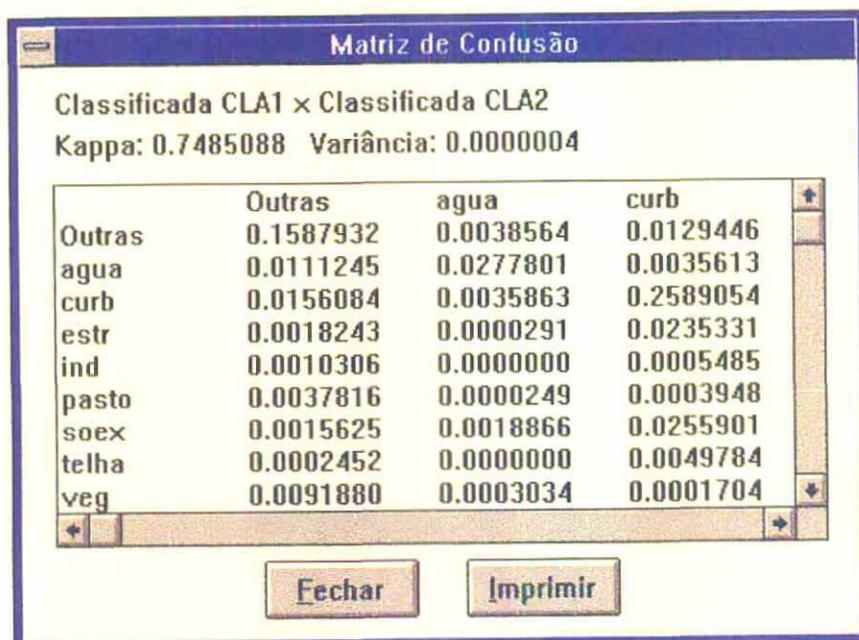


FIGURA 6.44 - Comparação entre Duas Classificações

Extração de Uma Classe

A partir de uma imagem classificada, é possível extrair os pixels classificados em determinada classe. Isto é realizado através da função *extrair classe*. O resultado desta função é apresentado numa janela do tipo *banda*, onde os pixels pertencentes à classe extraída são apresentados em cor branca. Este tipo de informação pode ser comparado através das operações lógicas entre duas bandas ou análise comparativa entre as bandas representando as classes (FIGURA 6.45).

Análise Comparativa Entre Bandas

Esta função realiza a comparação entre os pixels de duas janelas do tipo *banda*. O processo de comparação determina, simultaneamente:

- pixels com nível de cinza maior que zero nas duas bandas (apresentados em cor amarela);
- pixels com nível de cinza zero nas duas bandas (apresentados em cor preta);
- os pixels com nível zero em uma das bandas e maior que zero na outra (apresentados, respectivamente, nas cores vermelho e azul).

Essa função permite um grande número de combinações de comparações. O resultado é apresentado numa janela do tipo *classificada* (FIGURA 6.46).

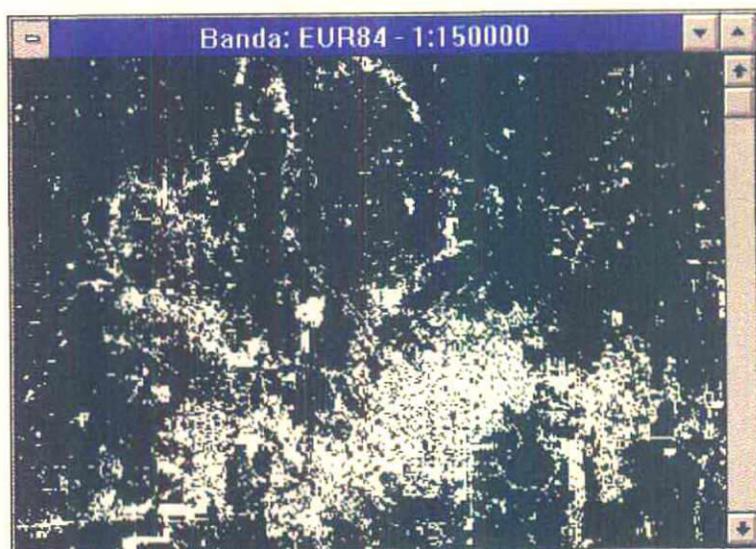


FIGURA 6.45 - Classe Extraída de uma Classificada

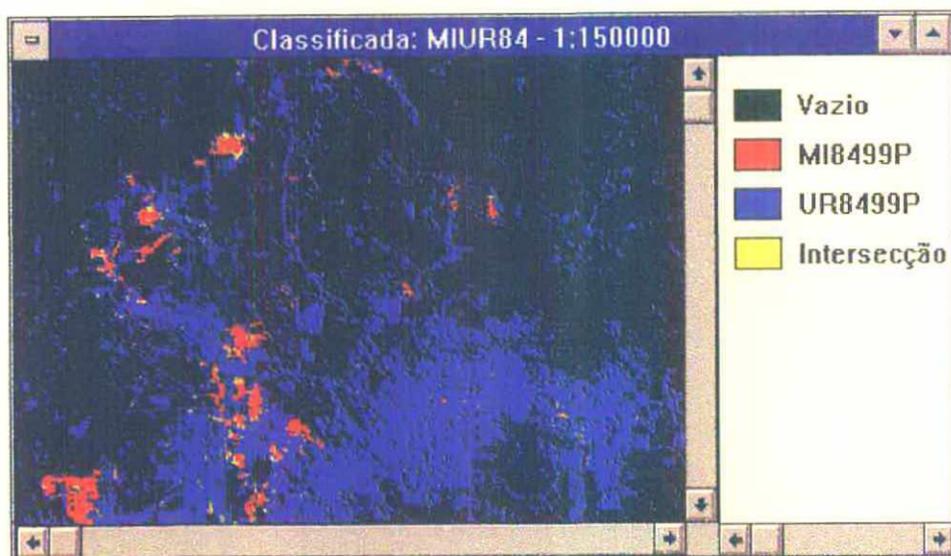


FIGURA 6.46 - Resultado da Comparação entre Duas Bandas

6.3.5 Considerações Finais

Sistemas computacionais direcionados ao processamento digital de imagens normalmente apresentam dificuldades relacionadas ao custo do hardware e à complexidade das tarefas que devem ser implementadas. O sistema EDIMA permite analisar imagens digitais de uma forma simples e direta. O sistema EDIMA tem, como ponto positivo, o fato de ter sido desenvolvido em uma plataforma do tipo PC. Esse tipo de plataforma é extremamente difundida em termos de mercado e, conseqüentemente, os custos de hardware associados são extremamente baixos.

O ambiente Windows permite desenvolver uma interface extremamente amigável, suprindo-se requisitos necessários de comunicabilidade entre o usuário e o sistema.

A orientação a objeto permitiu desenvolver o sistema de forma extremamente compacta. Além desse ponto, novos desenvolvimentos e a integração de novas características ao sistema são tarefas facilitadas pela orientação a objetos. Em termos de manutenção (outro aspecto importante em sistemas computacionais), o paradigma adotado é um requisito fundamental.

As funções implementadas constituem-se num núcleo central de um sistema de processamento de imagens. Com a introdução de um método de classificação difusa de imagens, o EDIMA torna-se uma alternativa promissora aos sistemas existentes. Além de incorporar funções normalmente encontradas em sistemas existentes, o sistema EDIMA acrescenta um sistema de classificação que permite ultrapassar dificuldades teóricas dos métodos convencionais. A quantidade de novas informações que são obtidas através do sistema EDIMA é uma prova desse fato.

Dadas as características do sistema EDIMA, sua integração a sistemas do tipo SIG é perfeitamente plausível, não sendo requeridos esforços substanciais para tanto.

7. APLICAÇÕES DA ABORDAGEM PROPOSTA

7.1 Introdução

Neste capítulo, mostra-se, através de diversas aplicações, que a abordagem proposta é bastante adequada para casos em que é necessário obter-se informações a respeito da mistura entre classes.

Inicialmente ilustra-se como as informações difusas podem ser utilizadas em problemas de identificação de metaclasses. É utilizado o método de similaridade contextual difusa para determinação de padrões de classes de uso do solo.

A seguir, é realizada uma análise de crescimento, com o objetivo de identificar as áreas que estão sendo ocupadas pela expansão urbana, assim como a tendência verificada nessa expansão.

Com o objetivo de detectar mudanças ocorridas, proporcionando mais informação a respeito da natureza dessas mudanças, é desenvolvida uma aplicação.

Finalmente, é apresentada uma análise sobre o desempenho do classificador difuso desenvolvido. Para a realização dessa análise, dados reais e de uma imagem sintética são utilizados.

7.2 Identificação de Metaclasses Através de Informações Difusas

O planejamento urbano de municípios baseia-se, entre outros aspectos, no conhecimento de sua estrutura urbana geral, que corresponde à mistura entre os variados padrões de ocupação do solo e a estrutura viária. A partir desse conhecimento, devem ser definidas as regras de uso e ocupação do

solo, que referenciam a ação dos que constroem e habitam na área urbana, e que são expressas na lei de zoneamento.

Nesse contexto, verifica-se a necessidade do levantamento dos vários tipos de uso do solo.

A utilização de dados obtidos por sensoriamento remoto em nível orbital, permitindo a obtenção de produtos multiespectrais, auxilia na interpretabilidade das várias classes de uso do solo. Os dados digitais possibilitam o tratamento em sistemas de processamento.

As classes de uso do solo podem ser divididas em dois grupos: as que possuem ou são dominadas por uma única classe espectral na imagem, e as que são compostas por mais de uma classe espectral. Para GONG e HOWARTH (1990), as classes do primeiro grupo são chamadas de classes de cobertura do solo e as do segundo, de classes de uso do solo.

A área urbana é uma classe de uso do solo, sendo composta por classes espectrais heterogêneas. A mistura dessas classes espectrais, dentro da área urbana, geralmente ocorre de forma diferenciada. Regiões de área urbana consolidada (mais antiga) tendem a apresentar uma concentração maior de área construída, com pouco de solo exposto e de vegetação. Já uma área urbana mais nova tende a apresentar uma área construída mais espaçada, com maior mistura de vegetação e solo exposto. A essas diversificações existentes dentro de uma mesma classe de uso do solo denominou-se metaclasses.

Os métodos convencionais de classificação de imagens revelam-se muitas vezes problemáticos, no que se refere aos limites das classes e à própria resposta espectral, dentro de uma mesma classe. Esses métodos atribuem cada pixel a somente uma determinada classe, ou seja, a uma classe de cobertura do solo. Portanto, para os pixels que sejam representativos de cada uma das classes, não existem problemas, enquanto para pixels que representem as classes de uso do solo, ou seja, pixels com mais de uma classe espectral, podem ocorrer distorções, tanto no cálculo dos parâmetros representativos da classe como no próprio processo de classificação.

A introdução da teoria dos conjuntos difusos permite identificar os pixels bem representativos de cada classe, bem como os pixels mistos ou intermediários.

Na aplicação em questão, é mostrado como a teoria dos conjuntos difusos pode ser utilizada em problemas de identificação de metaclasses. Para determinação de tipos de uso do solo é aplicado o método de similaridade contextual difusa.

7.2.1 Procedimento Adotado

Para identificação de metaclasses, escolheu-se, como área de estudo, parte do município de Joinville, localizado no nordeste de Santa Catarina. Essa escolha deve-se ao fato de que se tem um bom conhecimento da área, em função de pesquisas anteriormente realizadas, com possibilidade de identificação de diferentes padrões, bem como por tratar-se de uma área com relativa disponibilidade de documentação, sob a forma de mapas, relatórios, etc.

Foram utilizadas imagens SPOT - pancromática e multiespectral, órbita/ponto: 713/403 de 25 de março de 1991.

Inicialmente, foi feito o registro da imagem multiespectral sobre a pancromática, utilizando treze pontos de controle, sendo o erro obtido inferior a um pixel para todos os pontos. Em seguida, procedeu-se à filtragem espacial nas bandas da imagem multiespectral, utilizando-se um filtro passa-alta com a seguinte máscara:

0	0	-2	0	0
0	1	-2	1	0
-2	-2	18	-2	-2
0	1	-2	1	0
0	0	-2	0	0

A transformação RGB/IHS foi realizada na imagem multiespectral, com as bandas 1,2 e 3 nos canais R, G e B, respectivamente. Para o retorno IHS/RGB, a banda I foi substituída pela imagem pancromática. Finalmente, nas bandas resultantes, foi aplicada uma transformação linear por partes. A FIGURA 7.1 mostra a composição colorida da imagem original (bandas 1,2 e 3) e a FIGURA 7.2 apresenta a composição colorida resultante do tratamento realizado (bandas R, G e B). Pode-se observar que a utilização dessas técnicas ocasionou uma melhoria na qualidade visual da imagem.

A classificação difusa foi realizada utilizando as bandas R, G e B. Foram definidas nove classes de cobertura do solo, com base no conhecimento existente sobre a área. Essas classes foram as seguintes: água, construção antiga, construção nova, estrada, área industrial, mangue, solo exposto, vegetação e vegetação intra-urbana. Essas nove classes não abrangem toda a cobertura do solo existente na área; então, as classes restantes foram englobadas na classe outras.

Para cada uma das classes, foram selecionadas áreas de treinamento. Como resultado da classificação, obteve-se, para cada pixel da imagem, o valor de pertinência a cada uma das classes.

Foram definidas duas metaclasses a serem identificadas: residencial antiga e residencial nova. De cada uma dessas metaclasses foram selecionadas áreas de treinamento. Essas áreas foram escolhidas de forma que, em cada uma delas, houvesse uma quantidade de classes de cobertura do solo que se considerava representativa do padrão.

Das áreas de treinamento das metaclasses foram extraídas informações contextuais. Em cada pixel da área de treinamento, foi aplicada uma janela $m \times m$. A pertinência do pixel central da janela em cada uma das classes foi recalculada, sendo substituída pela média difusa da pertinência dos pixels da janela na classe correspondente. Foram aplicados diferentes tamanhos de janela, sendo os melhores resultados obtidos com uma janela de tamanho 21×21 .

Composição RGB: ILEA321 - 1:35000

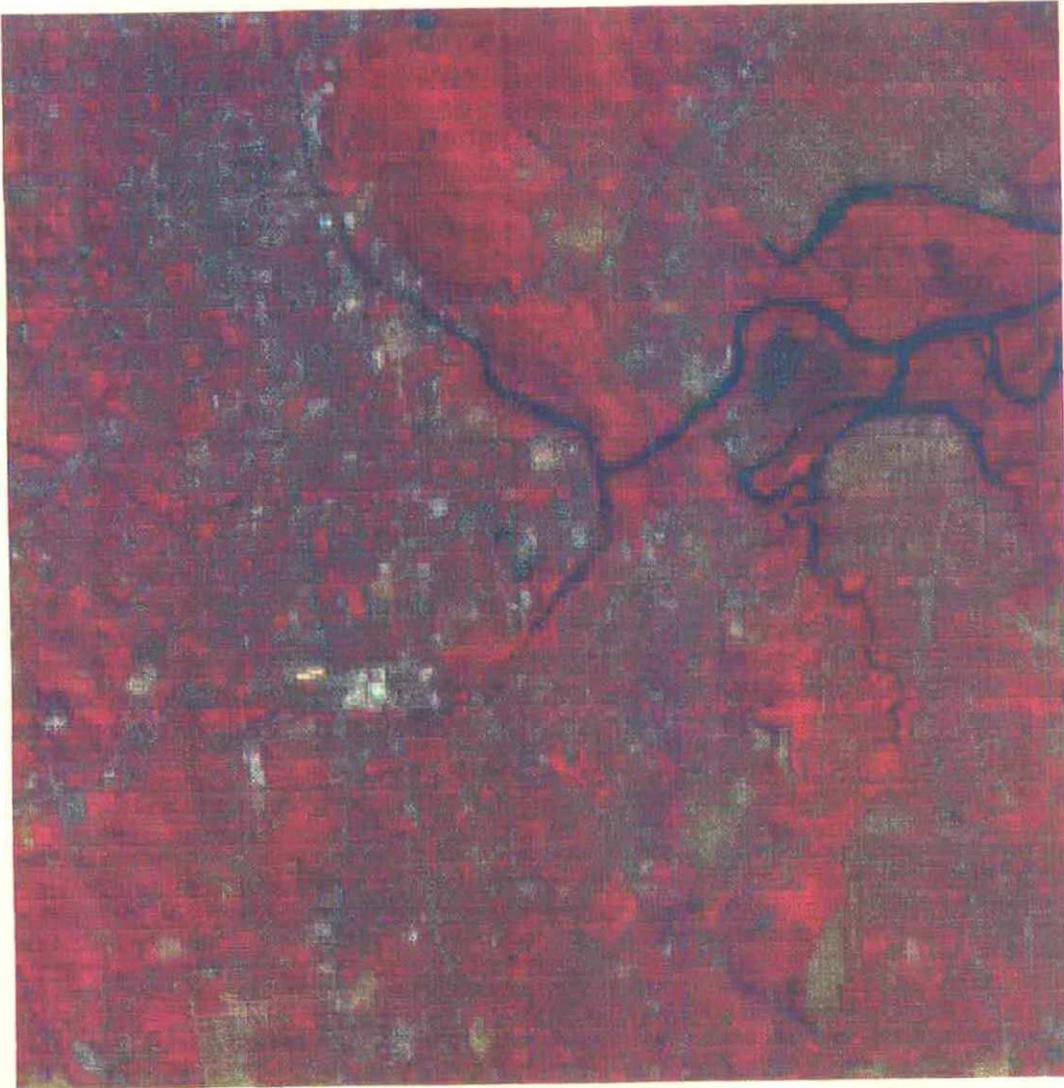


FIGURA 7.1 - Imagem Original - bandas 1,2 e 3

Composição RGB: RGB - 1:35000



FIGURA 7.2 - Imagem Resultante - bandas R, G e B

Após esse procedimento, foi calculada a pertinência média dos pixels das áreas de treinamento, por classe, sendo estas adotadas como padrão da metaclassa. As TABELAS 7.1 e 7.2 apresentam os padrões de cada uma das metaclasses definidas.

TABELA 7.1 - Padrão para Metaclassa 1: Residencial Antiga

CLASSE	PERTINÊNCIA
Água	0.004
Construção Antiga	0.304
Construção Nova	0.184
Estrada	0.174
Área Industrial	0.060
Mangue	0.028
Solo Exposto	0.005
Vegetação	0.036
Vegetação Intra-Urbana	0.082
Outras	0.123

TABELA 7.2 - Padrão para Metaclassa 2: Residencial Nova

CLASSE	PERTINÊNCIA
Água	0.013
Construção Antiga	0.086
Construção Nova	0.416
Estrada	0.127
Área Industrial	0.095
Mangue	0.004
Solo Exposto	0.052
Vegetação	0.030
Vegetação Intra-Urbana	0.065
Outras	0.112

Para cada um dos pixels da imagem foi aplicada a janela 21 x 21, sendo a sua pertinência em cada uma das classes substituída pela média das pertinências dos pixels da janela na classe correspondente.

A classificação dos pixels da imagem, em cada uma das metaclasses, foi feita utilizando uma medida de similaridade difusa entre o pixel e o padrão da metaclassa (equação 5.7, capítulo 5).

Foram testados diversos limiares, sendo 0.6 o que melhor identificou as metaclasses consideradas. Isso significa que o pixel foi atribuído à metaclassa se a similaridade entre ele e o padrão da metaclassa foi maior ou igual a 0.6. As FIGURAS 7.3 e 7.4 mostram na imagem, respectivamente, a identificação da metaclassa 1 e da metaclassa 2. Na FIGURA 7.5 é mostrado o cruzamento entre duas metaclasses.

Banda: PAD_RES1 - 1:35000

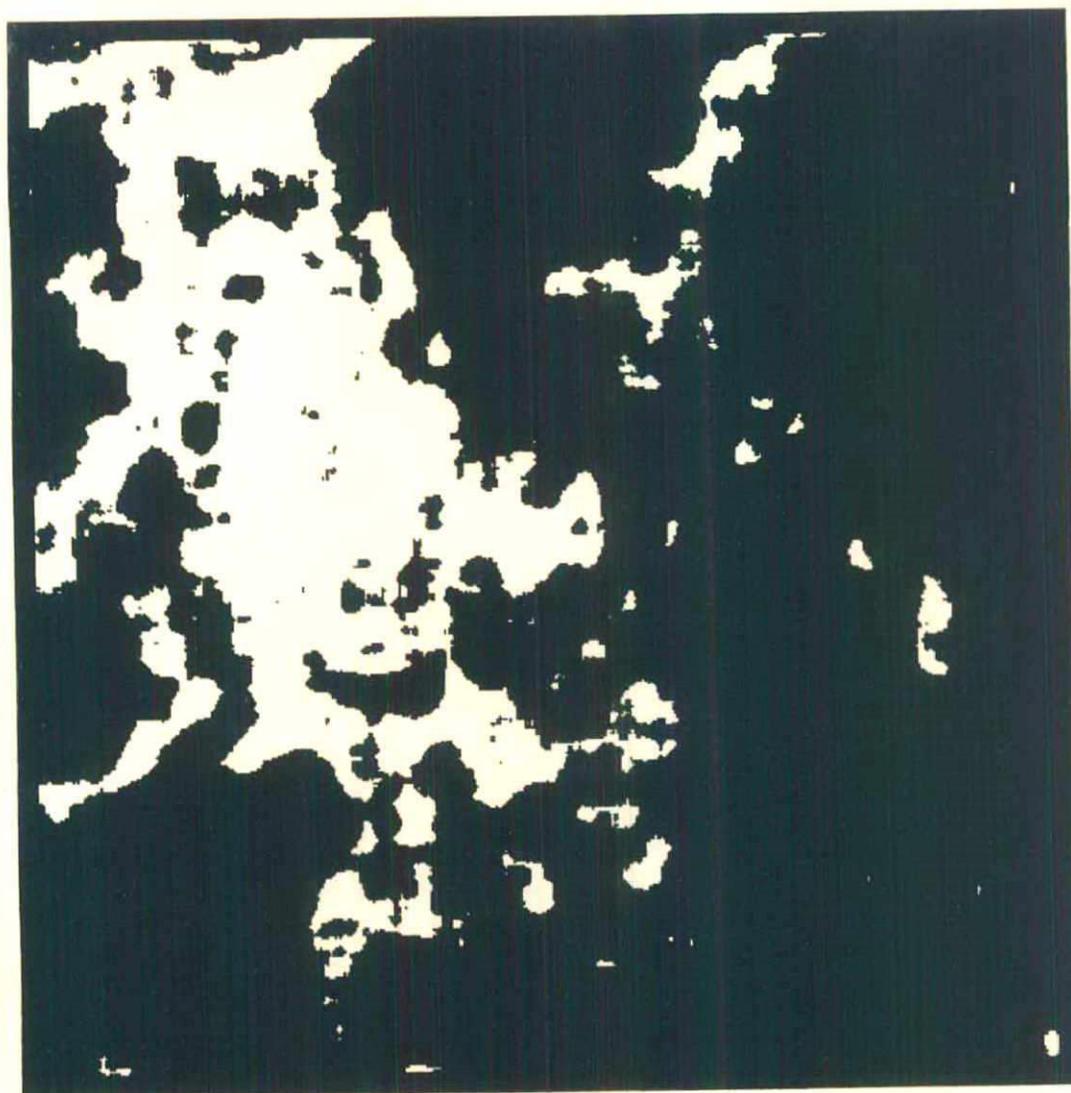


FIGURA 7.3 - Identificação da Metaclasse 1 - Residencial Antiga

Banda: PAD_RES2 - 1:35000

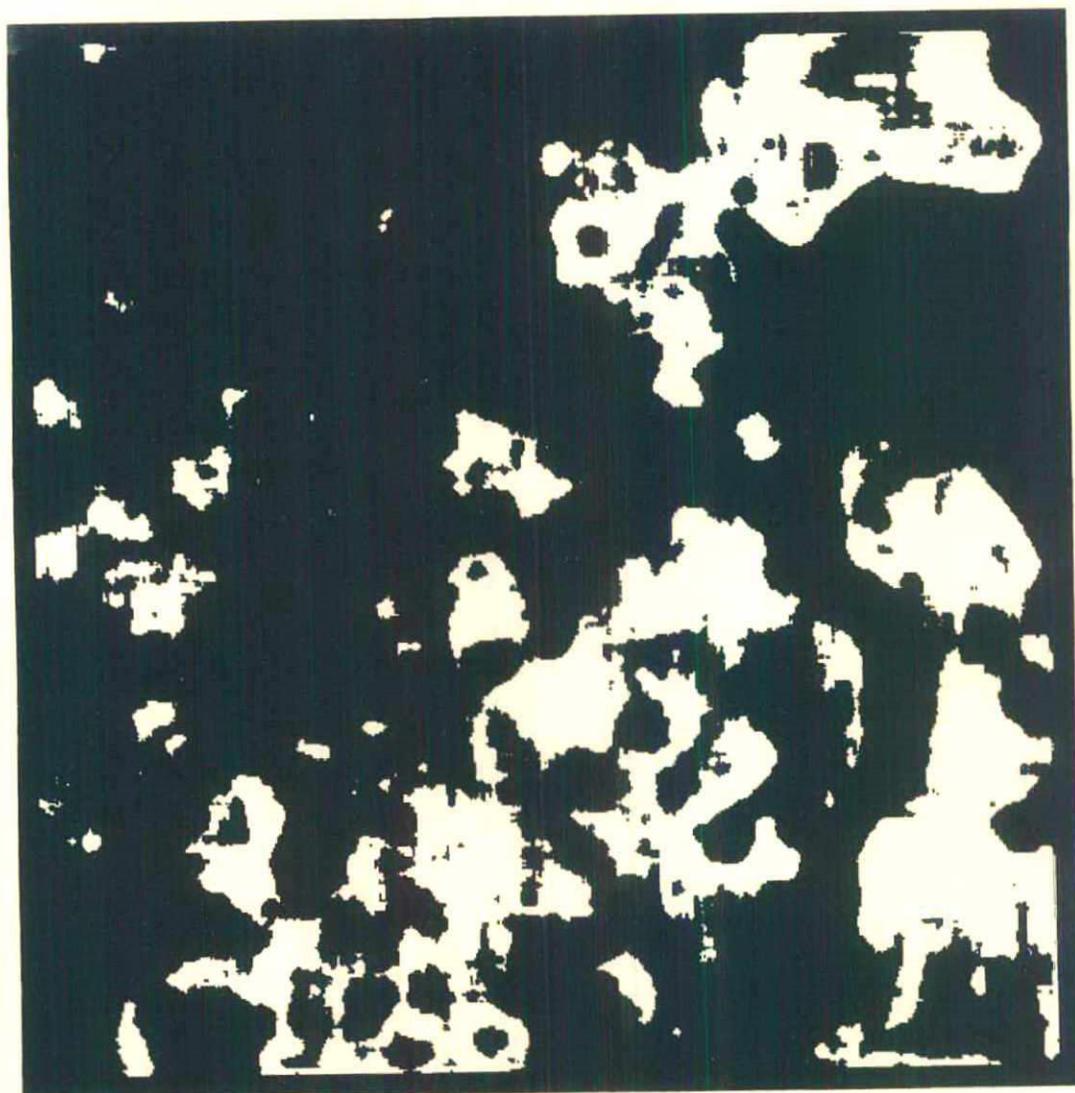


FIGURA 7.4 - Identificação da Metaclasse 2 - Residencial Nova

Classificada: RES1RES2 - 1:35000

■ Vazio ■ PAD_RES1 ■ PAD_RES2 ■ Intersecção

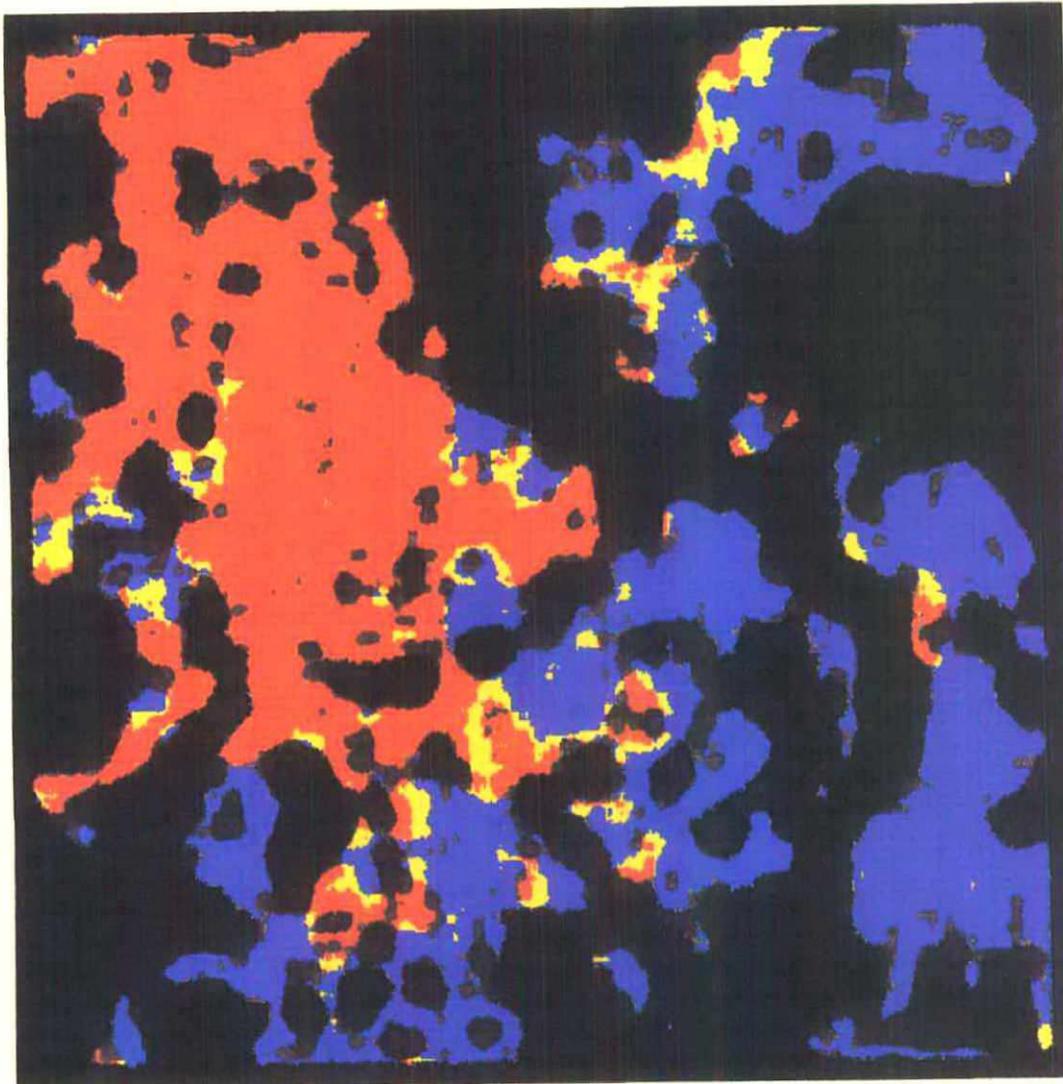


FIGURA 7.5 - Cruzamento das Metaclases 1 e 2

7.2.2 Análise dos Resultados

Os resultados evidenciam que a classificação utilizando informação difusa e análise de contexto apresenta classes bastante compactas. As diferentes regiões da imagem que correspondem a cada uma das metaclasses são compostas por pixels adjacentes que formam polígonos.

Pelo conhecimento a priori da área de estudo, se a imagem for dividida em quatro quadrantes, observa-se que, no quadrante superior esquerdo, tem-se uma área residencial antiga (zona central de Joinville); os quadrantes superior e inferior direito correspondem a uma área residencial nova (próxima à área de mangue); o quadrante inferior esquerdo apresenta-se como uma área de transição (área de expansão urbana).

A imagem resultante apresenta, no quadrante superior esquerdo, praticamente, só a metaclasses 1 (a área correspondente à metaclasses 2 é desprezível). Nos quadrantes superior e inferior direito predomina quase que totalmente a metaclasses 2, enquanto, no quadrante inferior esquerdo, percebe-se uma mistura das duas metaclasses (FIGURA 7.5).

Pode-se perceber que o método aplicado permite uma boa separação das metaclasses, pois as áreas de intersecção entre elas são irrelevantes. Além disso, consegue identificar de maneira correta as metaclasses, existindo uma correspondência entre as áreas consideradas como verdade terrestre para os padrões 1 e 2 e as áreas identificadas como metaclasses 1 e 2, na imagem resultante.

Conclui-se que a abordagem proposta é bastante promissora na identificação de áreas em que existam classes de uso do solo formadas por elementos com respostas espectrais diferentes.

7.3 Análise de Crescimento

Imagens obtidas por sensoriamento remoto, em diferentes épocas, permitem a identificação das alterações verificadas numa certa área de interesse.

As análises multitemporais ressaltam em importância no estudo de áreas urbanas, pois fornecem valiosos subsídios para os planejadores e tomadores de decisão.

A análise do crescimento ocorrido permite identificar as áreas que estão sendo ocupadas pela expansão urbana, bem como a tendência verificada nessa expansão. Com isso, os tomadores de decisão podem direcionar essa expansão, impedindo que áreas inadequadas sejam ocupadas e que o crescimento ocorra desordenadamente.

7.3.1 Procedimento Adotado

Para realizar a análise de crescimento, foi escolhida, como área teste, parte do município de Criciúma, situado ao sul do Estado de Santa Catarina. Utilizaram-se duas imagens LANDSAT TM-5 (WRS: 220/80), uma de 3 de março de 1984 e a outra de 6 de novembro de 1988, bandas 3,4 e 5. As imagens foram registradas e foi realizada a manipulação de contraste, para melhorar sua qualidade visual. Uma composição colorida da imagem de 1984 é apresentada na FIGURA 7.6, com as bandas 4, 5 e 3 nos canais R, G e B, respectivamente. A FIGURA 7.7 apresenta a mesma composição para a imagem de 1988.

As imagens foram inicialmente classificadas utilizando-se o classificador difuso. Em ambas, foi feito um corte alfa de 0.5. Dessa forma, além de incluir os pixels bem representativos da classe de interesse (pertinência 1.0), são considerados, também, aqueles que possuem um grau de pertinência entre 0.5 e 1.0, ou seja, aqueles em que a classe de interesse predomina.

Composição RGB: C453_84 - 1:100000

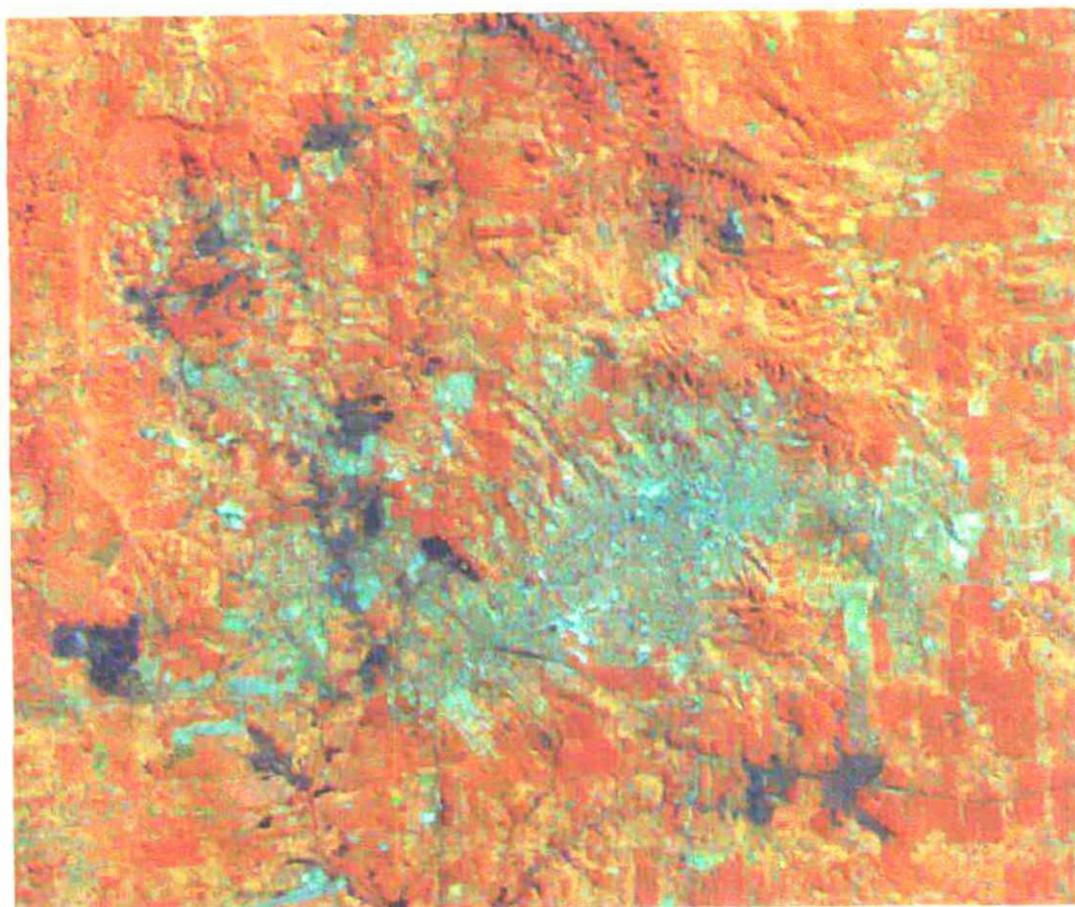


FIGURA 7.6 - Composição Colorida da Imagem de 03/05/84 - bandas 4,5 e 3

Composição RGB: C453_88 - 1:100000



FIGURA 7.7 - Composição Colorida da Imagem de 06/11/88 - bandas 4,5 e 3

A classe escolhida para análise foi a área urbana. Inicialmente, essa classe foi extraída das imagens classificadas. A FIGURA 7.8 mostra a área urbana da imagem classificada de 1984, e a FIGURA 7.9 apresenta a área urbana da imagem classificada de 1988.

A seguir, foi feito o cruzamento entre as áreas urbanas extraídas das imagens, utilizando-se a função análise de mudança do EDIMA. O resultado é mostrado na FIGURA 7.10, onde se pode perceber nitidamente a intersecção (em amarelo) entre as áreas urbanas das duas épocas, bem como as áreas de expansão (em azul). Do resultado do cruzamento, é possível extrair as seguintes informações:

- área urbana em 1984 e não urbana em 1988 (FIGURA 7.11);
- área não urbana em 1984 e urbana em 1988 (FIGURA 7.12);
- área não urbana em 1984 e não urbana em 1988 (FIGURA 7.13);
- área urbana em 1984 que permanece como urbana em 1988 (FIGURA 7.14).

As áreas correspondentes a cada uma das classes resultantes do cruzamento, são mostradas na TABELA 7.3.

TABELA 7.3 - Áreas das Classes Resultantes do Cruzamento

Classe	Área (Km ²)	Área (%)
Urbana 84	3.76	2.27
Urbana 88	23.81	14.36
Intersecção	22.60	13.63
Outras	115.65	69.74
Total	165.82	100.00

Banda: URB84 - 1:100000

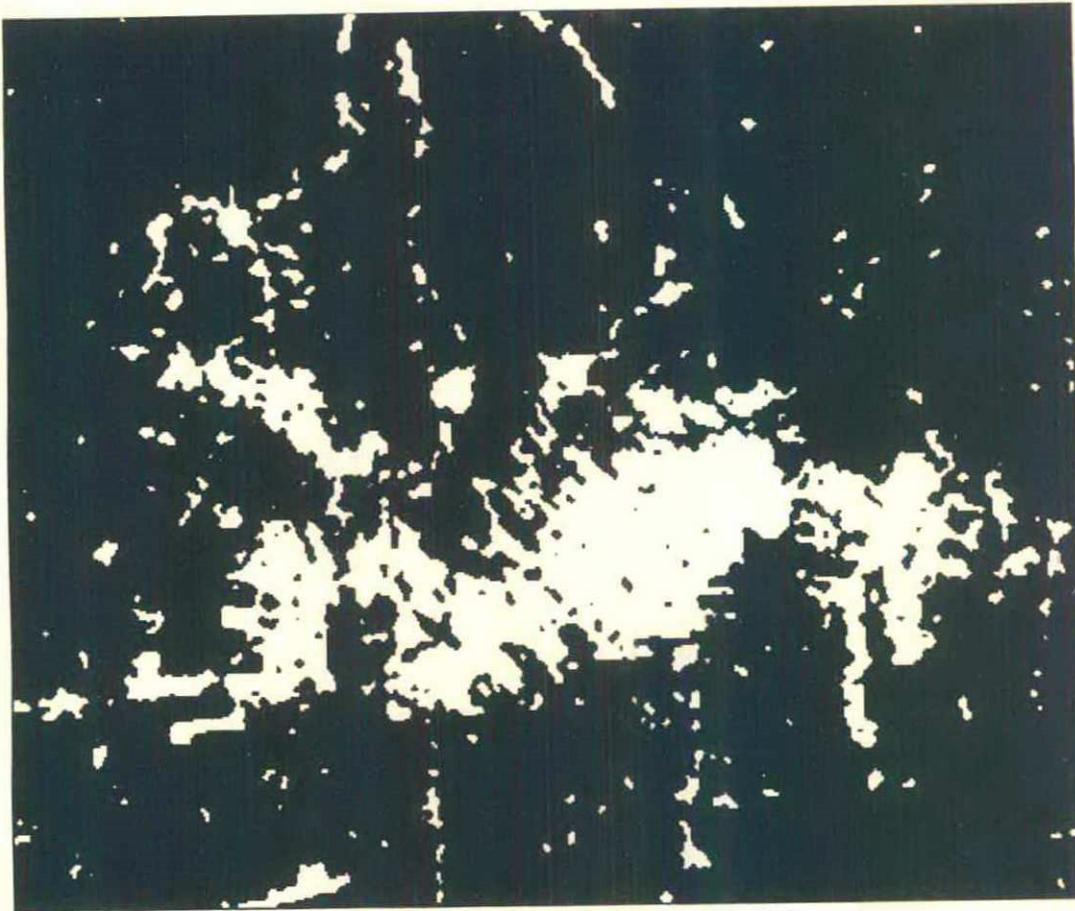


FIGURA 7.8 - Área Urbana Extraída da Imagem Classificada - 1984

Banda: URB88 - 1:100000

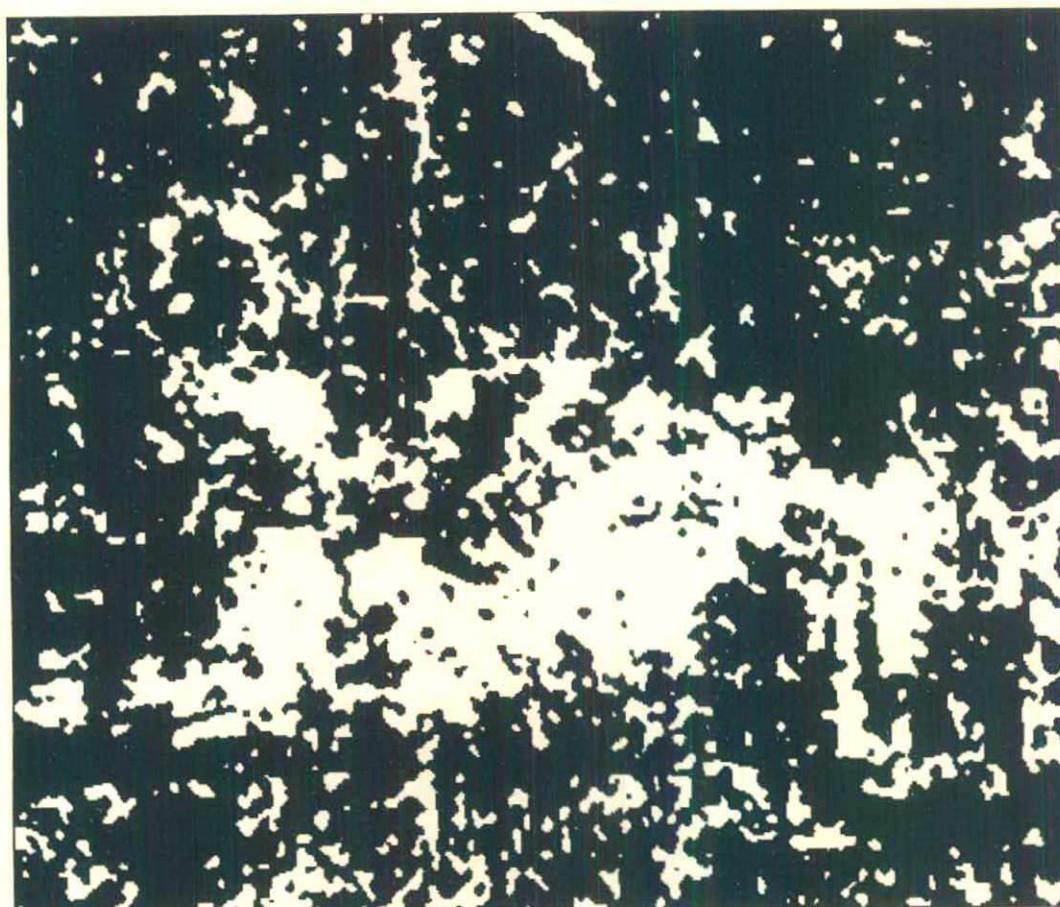


FIGURA 7.9 - Área Urbana Extraída da Imagem Classificada - 1988

Classificada: URB84_88 - 1:100000

■ Vazio ■ URB84 ■ URB88 ■ Intersecção

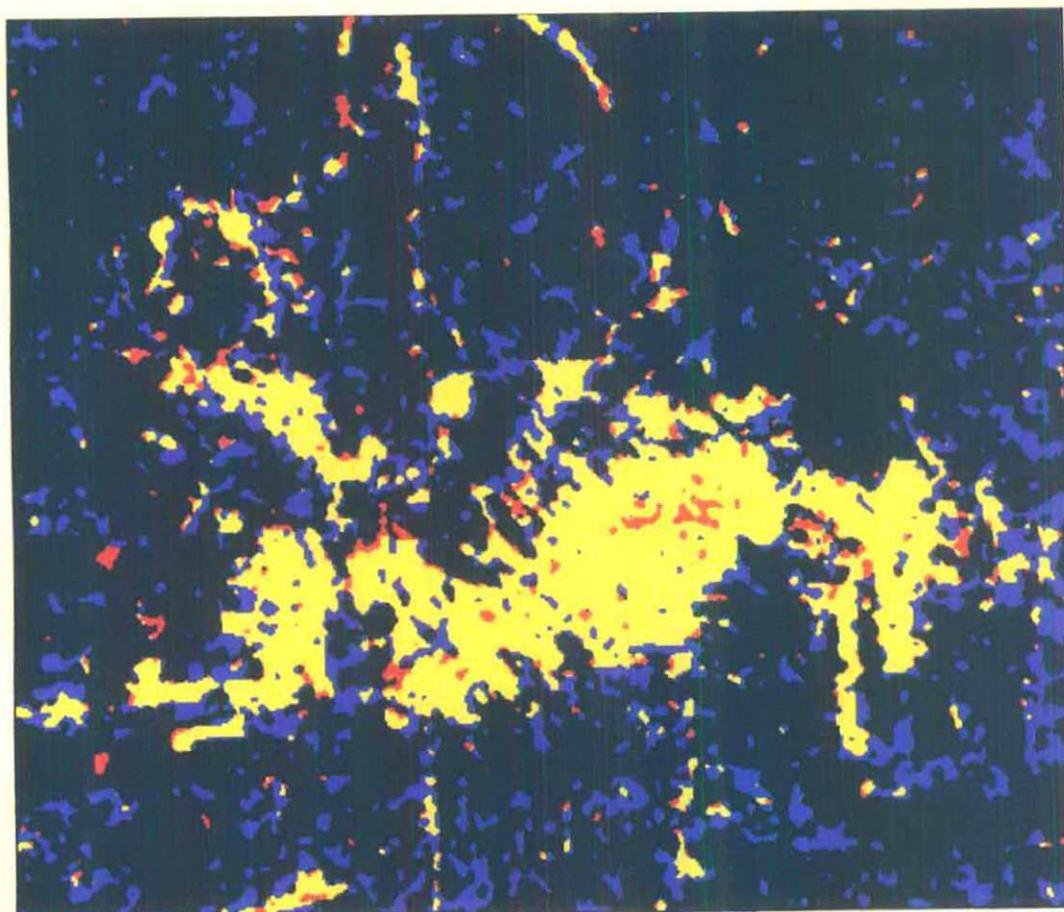


FIGURA 7.10 - Cruzamento entre Áreas Urbanas Extraídas das Imagens Classificadas - 1984/1988

Banda: URB84N88 - 1:100000

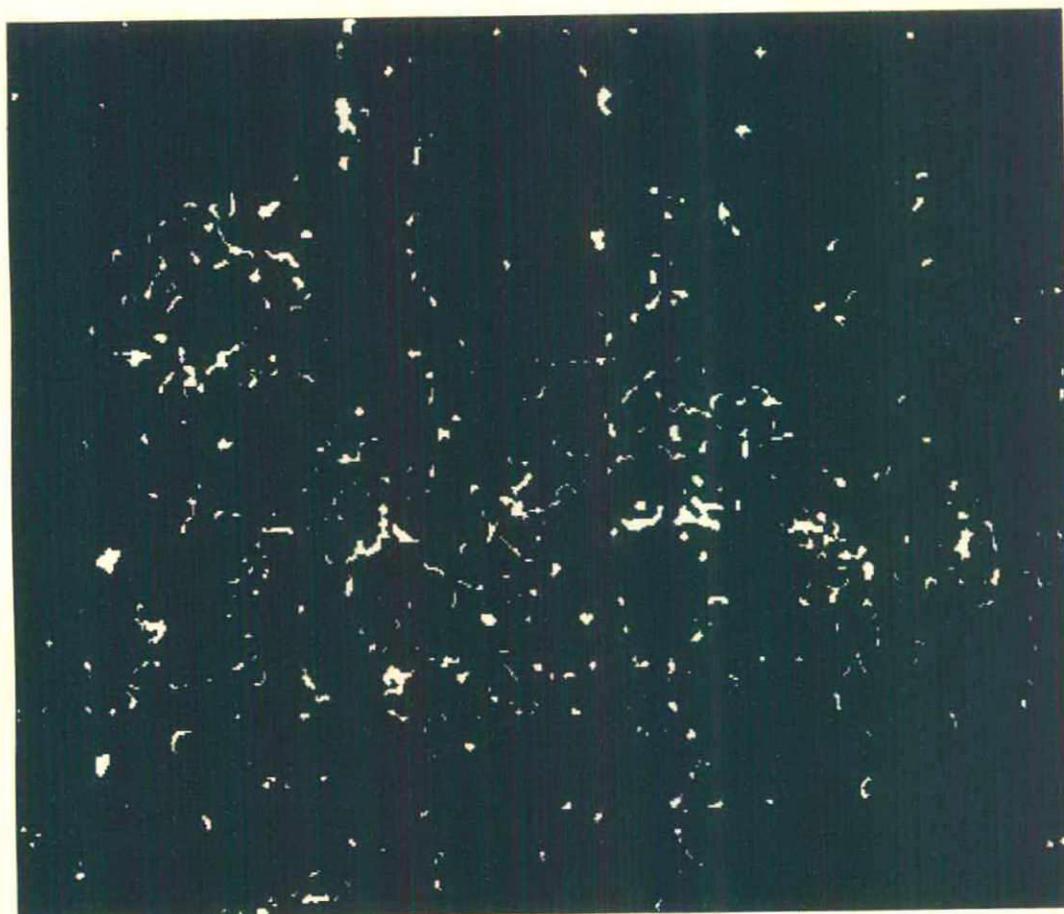


FIGURA 7.11 - Área Urbana em 1984 e Não Urbana em 1988

Banda: N84URB88 - 1:100000

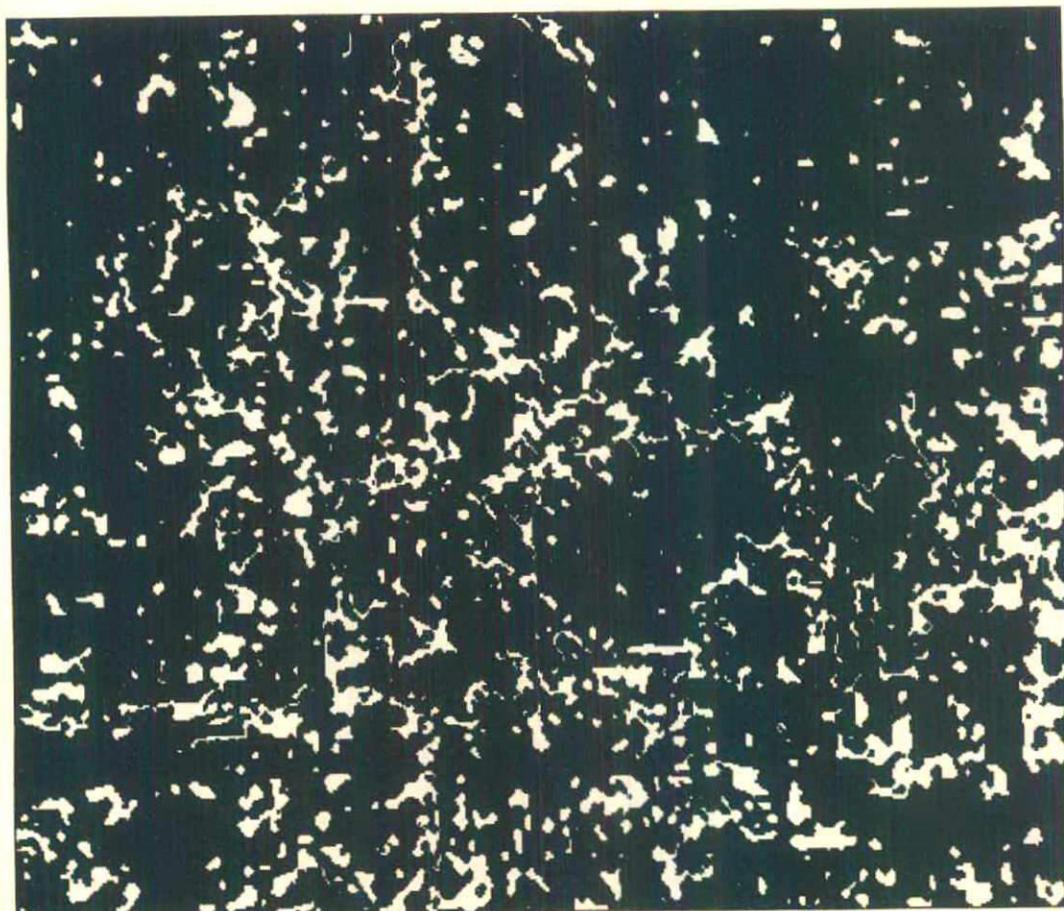


FIGURA 7.12 - Área Não Urbana em 1984 e Urbana em 1988

Banda: NURB8488 - 1:100000

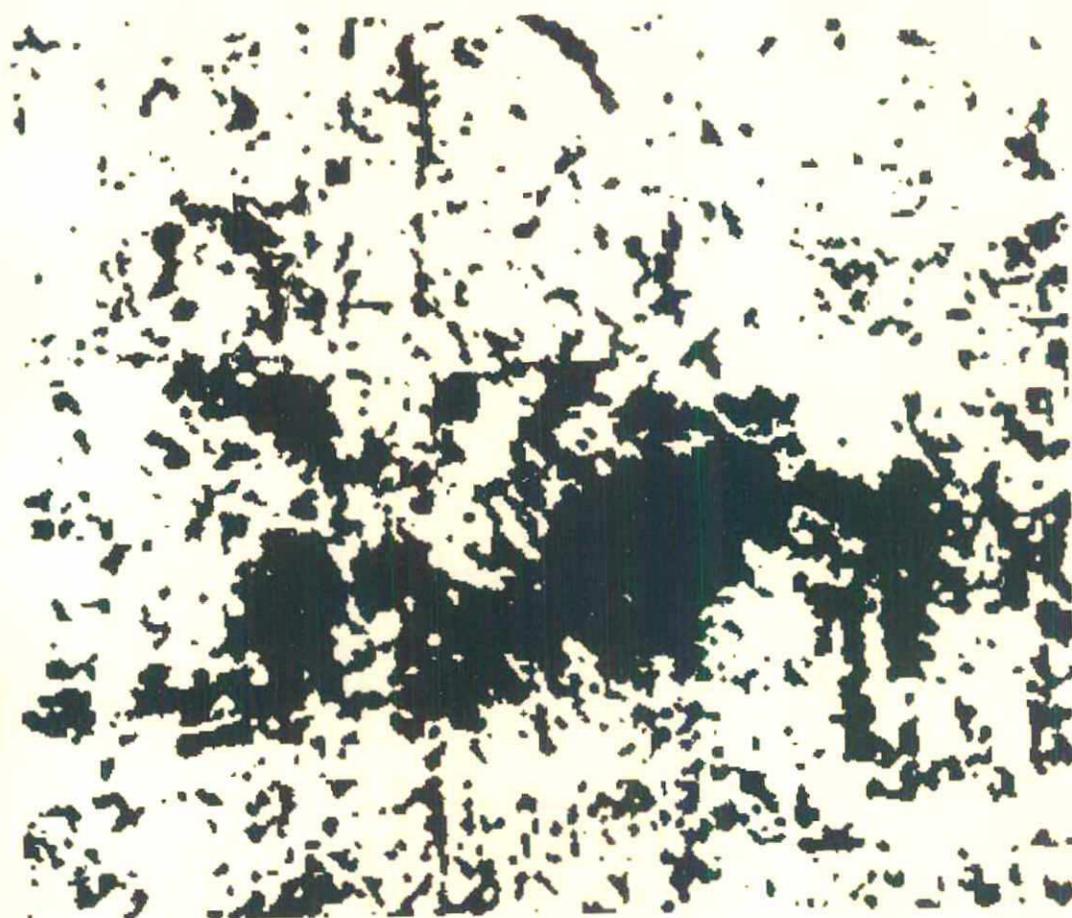


FIGURA 7.13 - Área Não Urbana em 1984 e Não Urbana em 1988

Banda: UR84UR88 - 1:100000

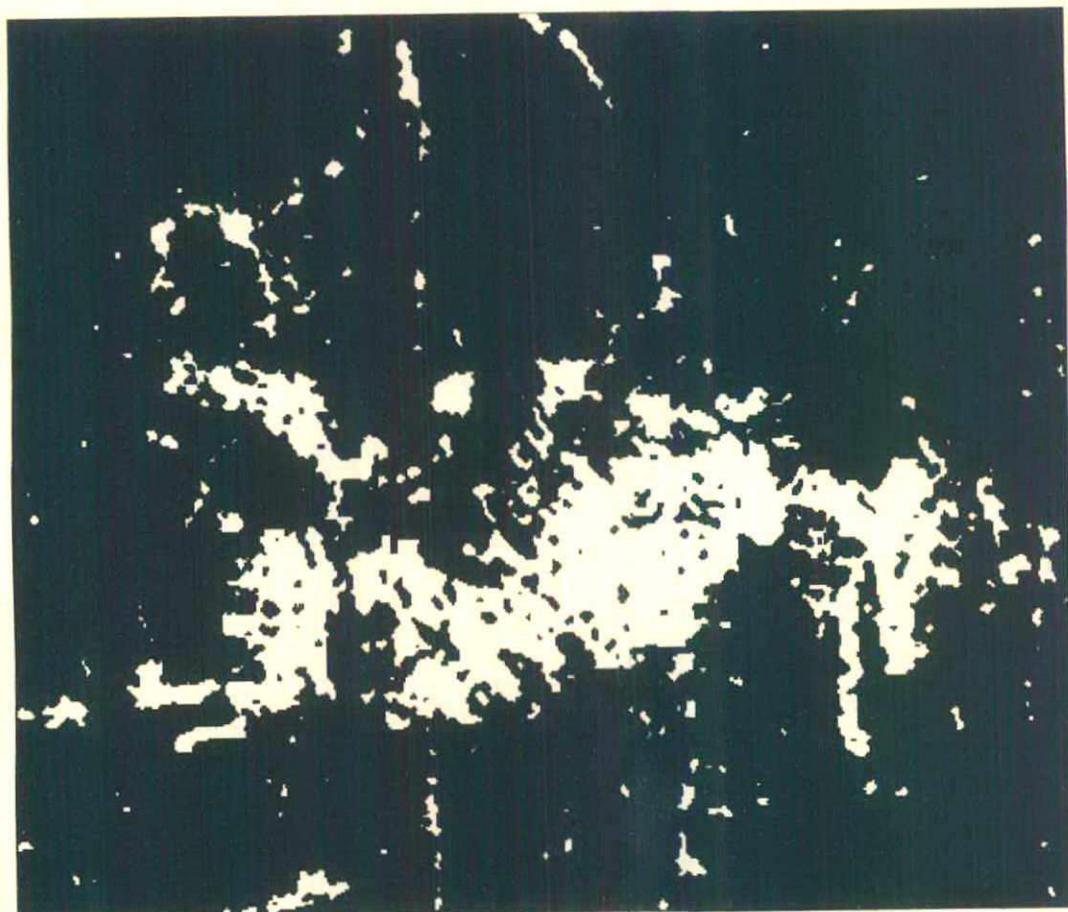


FIGURA 7.14 - Área Urbana em 1984 e Urbana em 1988.

7.3.2 Análise dos Resultados

Como área teste, utilizou-se uma imagem de parte do município de Criciúma, abrangendo 165.82 Km². Obteve-se, para 1984, um total de área urbana de 26.36 Km², correspondendo a 15.89% do total da área. Em 1988, a área urbana passou para 46.41 Km², ou seja, 27.89% do total da área. Isso representa um acréscimo de 76.02% de área urbana na região.

Uma análise da FIGURA 7.10, em que é feito o cruzamento entre as áreas urbanas de 1984 e 1988, permite identificar:

- a área em vermelho representa o que foi classificado como área urbana em 1984 e não urbana em 1988. Abrange um total de 3.76 Km², ou seja, apenas 2.27% da área total. Isso pode ser explicado por regiões com solo exposto em 1984 que foram cobertas por vegetação ou, devido a peculiaridade da região, por áreas de mineração que avançaram sobre áreas urbanas;

- a área em amarelo representa o que era urbano em 1984 e continuou sendo urbano em 1988. Corresponde a um total de 22.60 Km² (13.63% da área total) e abrange, na imagem, praticamente a parte central da mancha urbana;

- a área em azul representa a área de expansão urbana. Compreende um total de 23.81 Km², ou seja, 14.36% da área total. Nessa área, não se identificam tendências de crescimento numa determinada direção, pelo contrário, o que se pode perceber é um crescimento desordenado.

7.4 Detecção de Mudança

Para o planejamento e a administração dos recursos naturais, é necessário que se tenha um conhecimento preciso sobre o uso e a cobertura do solo. É importante detectar-se as tendências de mudanças. Por exemplo, em áreas onde devem coexistir uma urbanização intensiva e uma agricultura limitada,

deve-se pesquisar a conversão de áreas de agricultura primária em áreas suburbanas, impedindo a perda desse recurso renovável (JENSEN, 1986).

Nesta aplicação, a detecção de mudança consiste em identificar as áreas, que estão sendo utilizadas para expansão urbana servindo para ajudar a monitorar o processo de desenvolvimento urbano. Com esse tipo de informação, os planejadores poderão direcionar a ocupação das áreas urbanas, principalmente com a preocupação de preservar o meio ambiente.

Como o crescimento das áreas urbanas ocorre, principalmente, com a ocupação de áreas adjacentes, nas áreas de expansão urbana será encontrada uma mistura de área urbana com o tipo de cobertura do solo que está sendo ocupado. A detecção das mudanças ocorridas pode ser realizada, portanto, através da análise das áreas de mistura.

7.4.1 Procedimento Adotado

Para a detecção de mudança, também se utilizou, como área teste, parte do município de Criciúma, abrangendo, principalmente a sua área urbana. As imagens usadas foram as mesmas que serviram para a análise de crescimento. Após as etapas de pré-processamento, as imagens foram classificadas fazendo-se uso do classificador difuso.

Como o objetivo primeiro era identificar as misturas ocorridas, trabalhou-se com as bandas de pertinência das diversas classes. Inicialmente foi feito o cruzamento da banda de pertinência correspondente à área urbana com as bandas de pertinência das demais classes, nas duas datas, usando-se a função análise de mudanças do EDIMA, para verificação das classes que apresentavam mistura com a área urbana.

A seguir, foi feita a verificação do que apresentava mistura com área urbana na primeira época e passou a ser somente urbana na segunda. Para isso, foram utilizadas as imagens resultantes das intersecções dos cruzamentos anteriormente realizados que foram, por sua vez, cruzadas com a área urbana

extraída da classificada difusa da segunda data ao nível alfa 1.0 (que representa área urbana sem mistura).

Procurou-se, também, identificar o que representava mistura com área urbana na primeira data e continuou sendo mistura na data posterior. Para isso, foi feito o cruzamento entre as intersecções das bandas de pertinência da classe urbana com as demais classes da primeira data com as mesmas intersecções da segunda.

Para detectar as mudanças ocorridas de uma das classes para a classe urbana, foi feito o cruzamento entre os pixels que representavam uma única classe na primeira data (não urbana) com os que representavam somente área urbana na data posterior (usando, nos dois casos, as classes extraídas da imagem classificada com ao nível alfa 1.0).

Finalmente, as áreas correspondentes a cada um desses cruzamentos de classes são analisadas.

7.4.2 Análise dos Resultados

Os resultados obtidos nessa aplicação encontram-se sintetizados na TABELA 7.4. Em seguida esses resultados são comentados.

TABELA 7.4 - Síntese das Mudanças Ocorridas na Classe Área Urbana entre 1984 e 1988 (Km²)

Classes	Áreas das classes - 1984	Mudanças - 1984/1988		
		Área Urbana	Urb/Min	Urb/Pasto
Área de mineração	21.02	9.51	0.0	0.0
Gramínea	59.53	15.70	0.0	0.0
Vegetação	37.47	3.51	0.0	0.0
Min/Urb	0.85	0.32	0.0	0.0
Gramínea/Urb	16.48	8.51	0.0	1.58

Nas duas datas, a classe urbana apresentou mistura somente com as classes mineração e gramínea. As FIGURAS 7.15 e 7.16 apresentam as misturas entre urbana e mineração e urbana e gramínea, para a primeira data, e as FIGURAS 7.17 e 7.18 apresentam as mesmas misturas para a segunda data.

Considerando a mistura entre as áreas urbana e de mineração, verifica-se que essa mistura representava 0.85 Km^2 em 1984, passando para 2.11 Km^2 em 1988. A mistura entre área urbana e gramínea, que era de 16.48 Km^2 em 1984, diminuiu para 9.25 Km^2 em 1988.

A análise das áreas de mistura em 1984 que passaram a ser unicamente área urbana em 1988, demonstra que, dos 0.85 Km^2 de mistura entre área de mineração e urbana, 0.32 Km^2 passaram a ser somente urbana (FIGURA 7.19) o que corresponde a 37.6% da área inicial de mineração. Para o pasto (FIGURA 7.20) dos 16.48 Km^2 de mistura que havia em 1984, 8.51 Km^2 passou a ser unicamente área urbana (51.6% da área de mistura em 1984).

Considerando o que era mistura com área urbana em 1984 e continuou sendo mistura em 1988, a análise demonstrou que isso somente ocorreu com a classe gramínea (FIGURA 7.21). A área representada pela permanência dessa mistura corresponde a 1.58 Km^2 , ou seja, 9.5% da área de mistura entre essas classes em 1984.

Finalmente, a análise da área que correspondia somente a uma das classes (sem mistura) e passou a ser somente urbana, demonstrou que isso ocorreu com vegetação, área de mineração e gramínea (FIGURAS 7.22, 7.23 e 7.24, respectivamente). Verifica-se que isso ocorreu, para vegetação, com uma área de 3.51 Km^2 , de um total de 37.47 Km^2 de vegetação em 1984 (9.4% da área de vegetação); para a área de mineração, ocorreu numa área de 9.51 Km^2 , de um total de 21.02 Km^2 da área de mineração em 1984 (45.2 % da área original de mineração); para a gramínea, a área de mudança para urbana foi de 15.70 Km^2 de um total de 59.53 Km^2 (26.3% da área que era unicamente gramínea em 1984).

Classificada: MIUR84 - 1:100000

■ Vazio ■ MI8499P ■ UR8499P ■ Intersecção

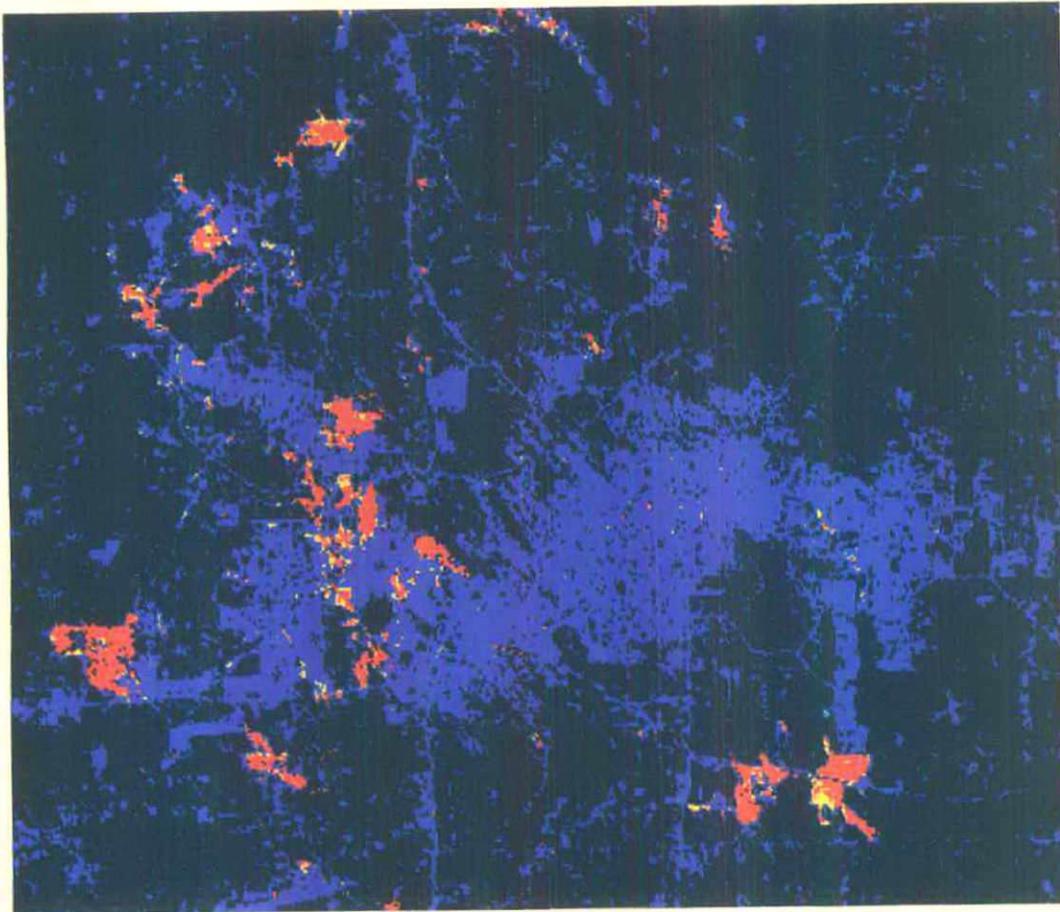


FIGURA 7.15 - Mistura entre as Classes Área de Mineração e Área Urbana - 1984

Classificada: PAUR84 - 1:100000

■ Vazio ■ PA8499P ■ UR8499P ■ Intersecção

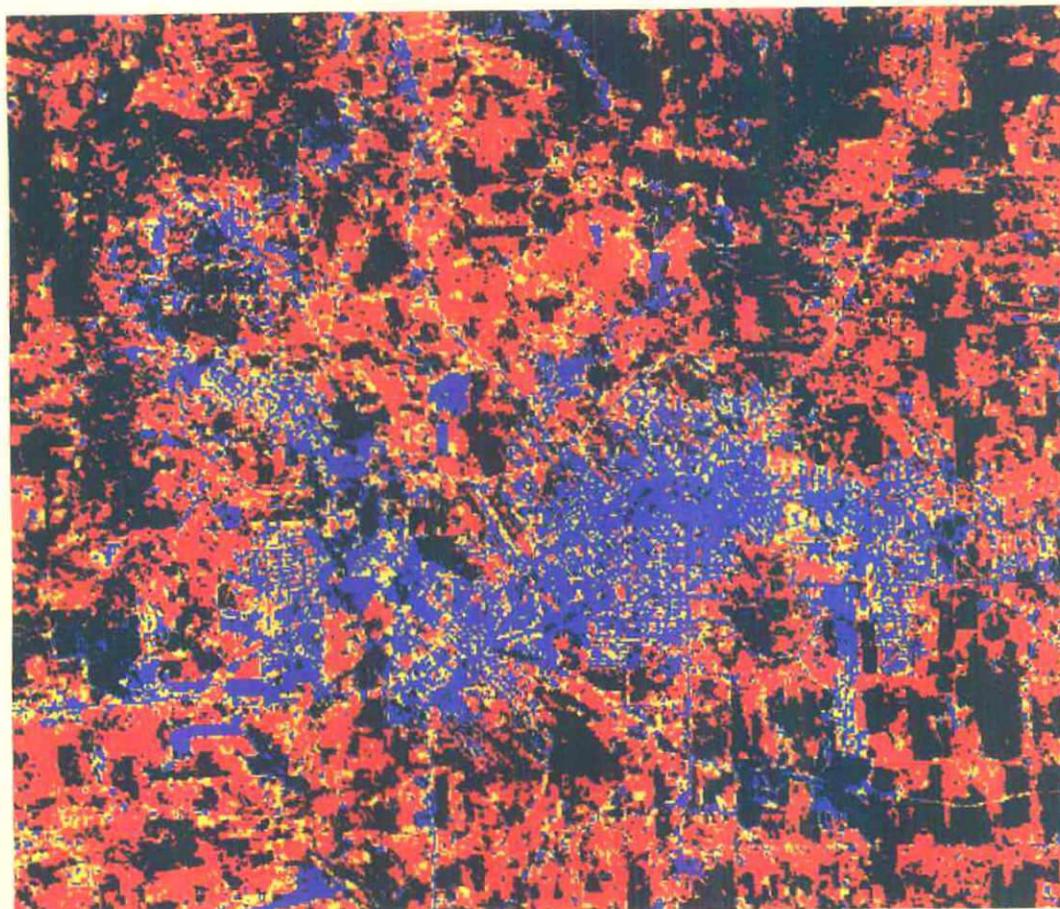


FIGURA 7.16 - Mistura entre as Classes Gramínea e Área Urbana - 1984

Classificada: MIUR88 - 1:100000

■ Vazio ■ MI8899P ■ UR8899P ■ Intersecção

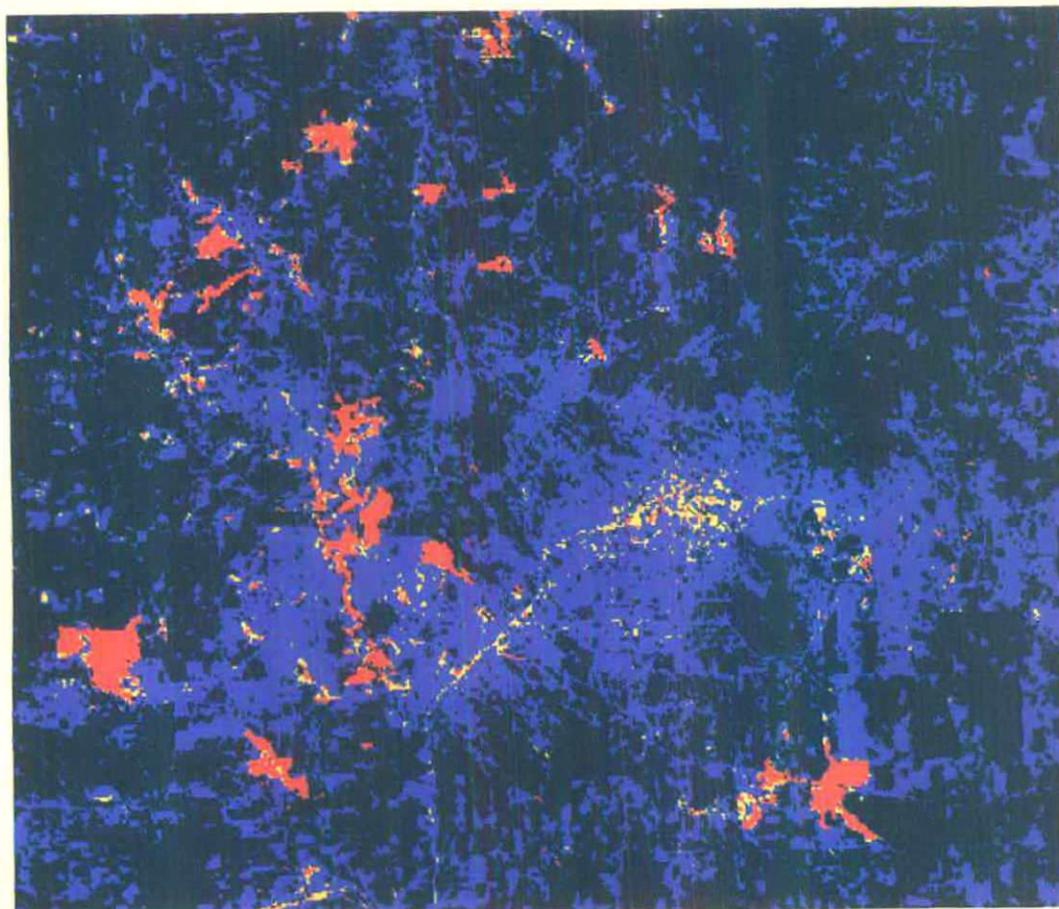


FIGURA 7.17 - Mistura entre as Classes Área de Mineração e Área Urbana - 1988

Classificada: PAUR88 - 1:100000

■ Vazio ■ PA8899P ■ UR8899P ■ Intersecção

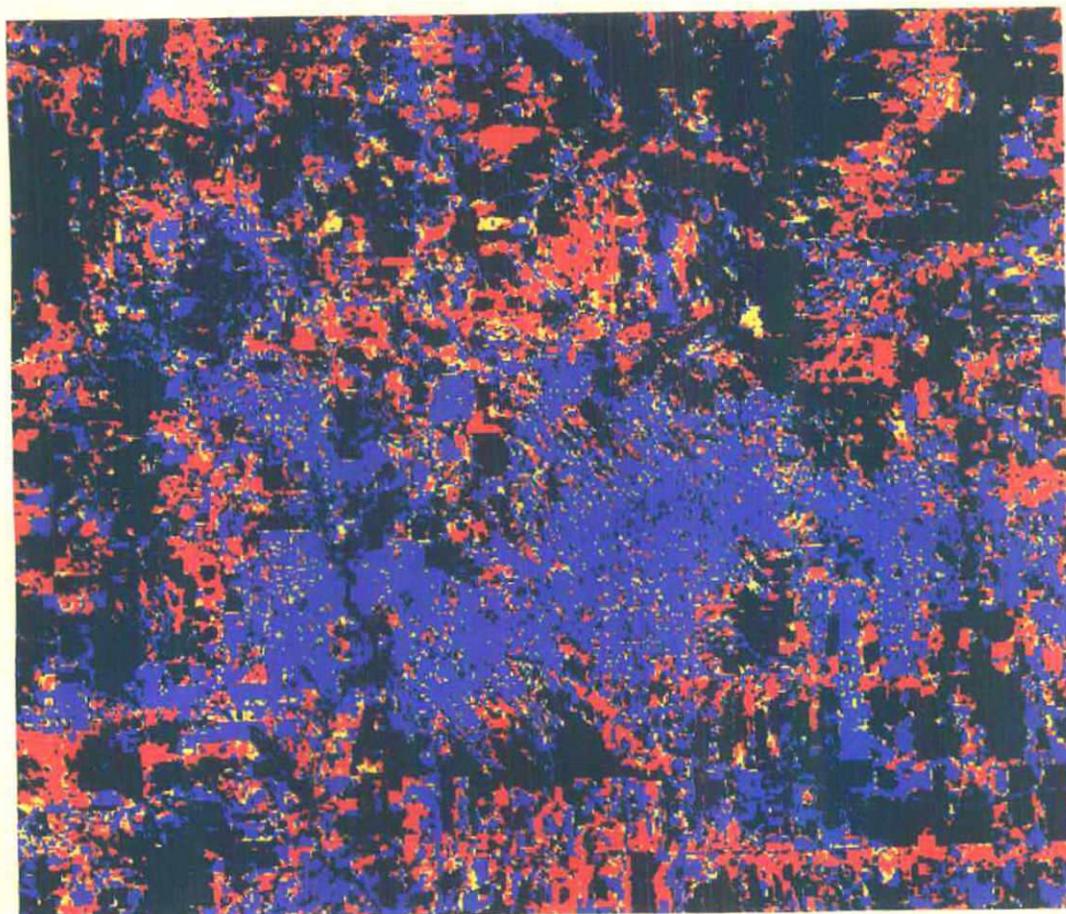


FIGURA 7.18 - Mistura entre as Classes Gramínea e Área Urbana - 1988

Classificada: IM84EU88 - 1:100000

■ Vazio ■ INMIUR84 ■ EUR88 ■ Intersecção

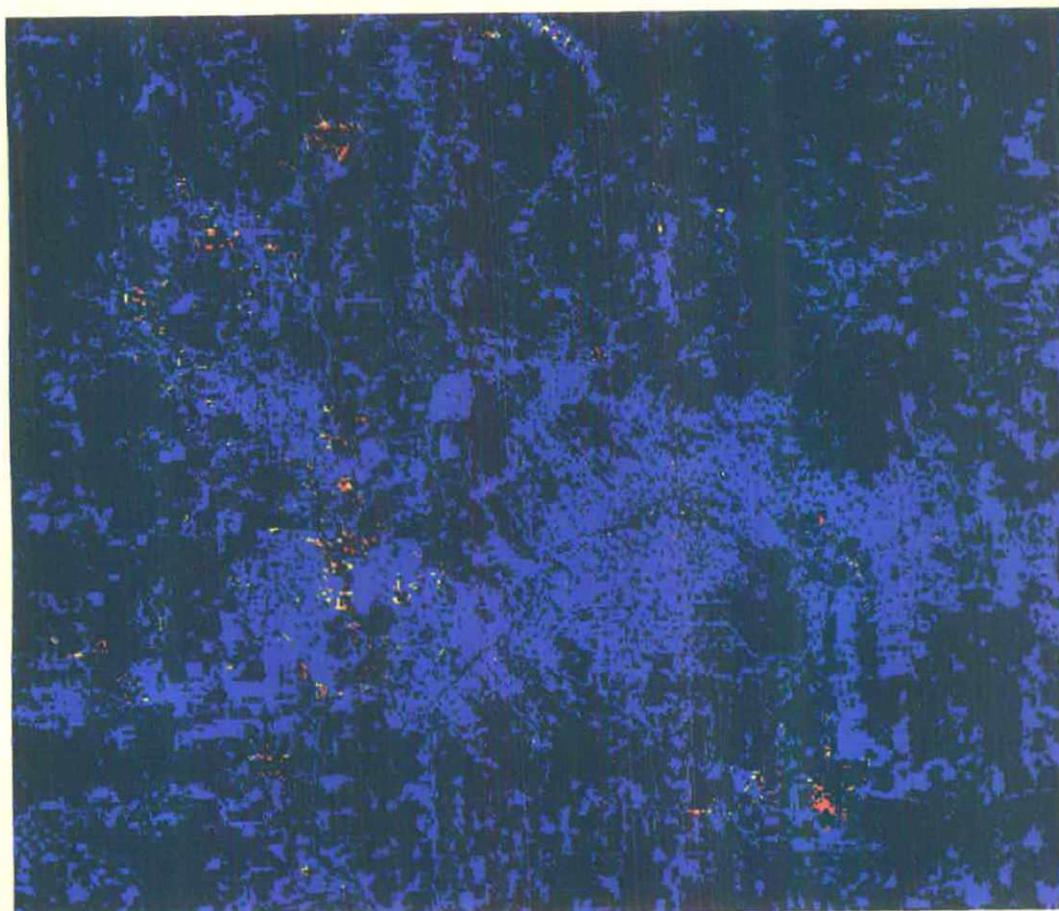


FIGURA 7.19 - Área de Mudança - Área de Mineração/ Área Urbana em 1984 para Área Urbana em 1988

Classificada: IP84EU88 - 1:100000

■ Vazio ■ INPAUR84 ■ EUR88 ■ Intersecção

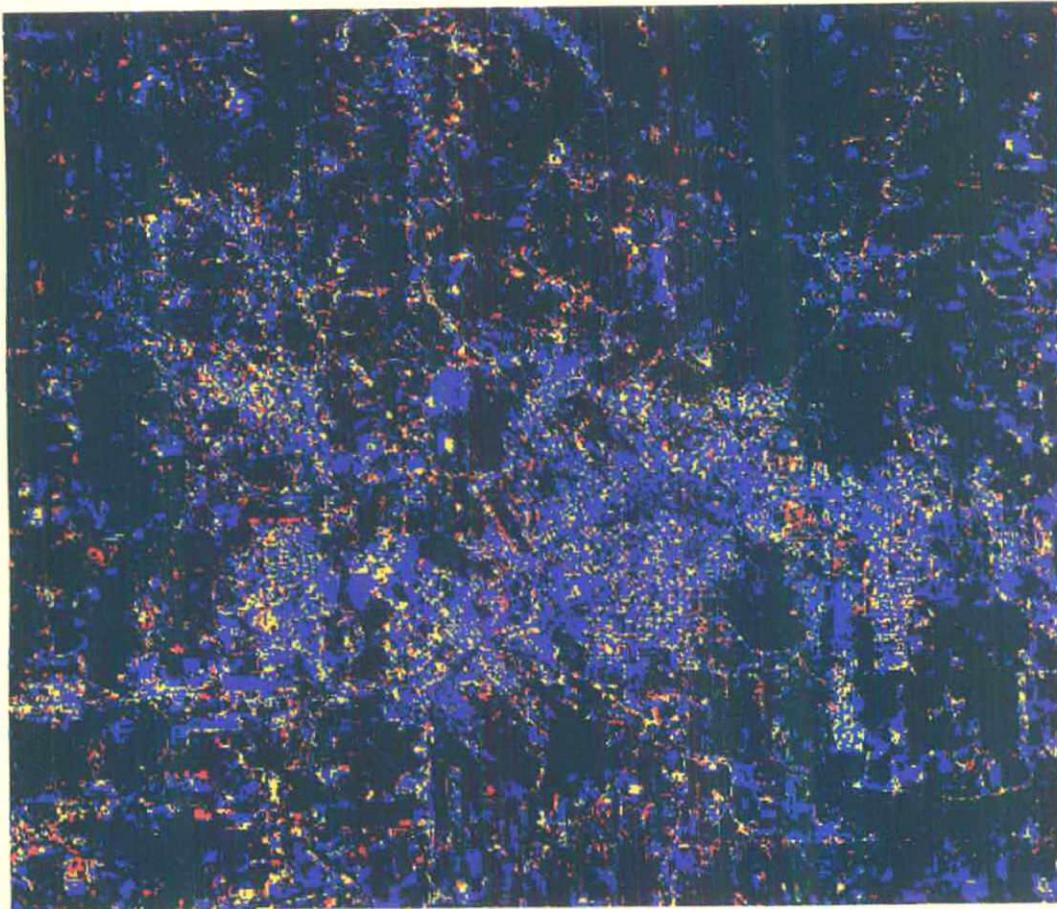


FIGURA 7.20 - Área de Mudança - Gramínea / Área Urbana em 1984 para Área Urbana em 1988

Classificada: IP84IP88 - 1:100000

■ Vazio ■ INPAUR84 ■ INPAUR88 ■ Intersecção

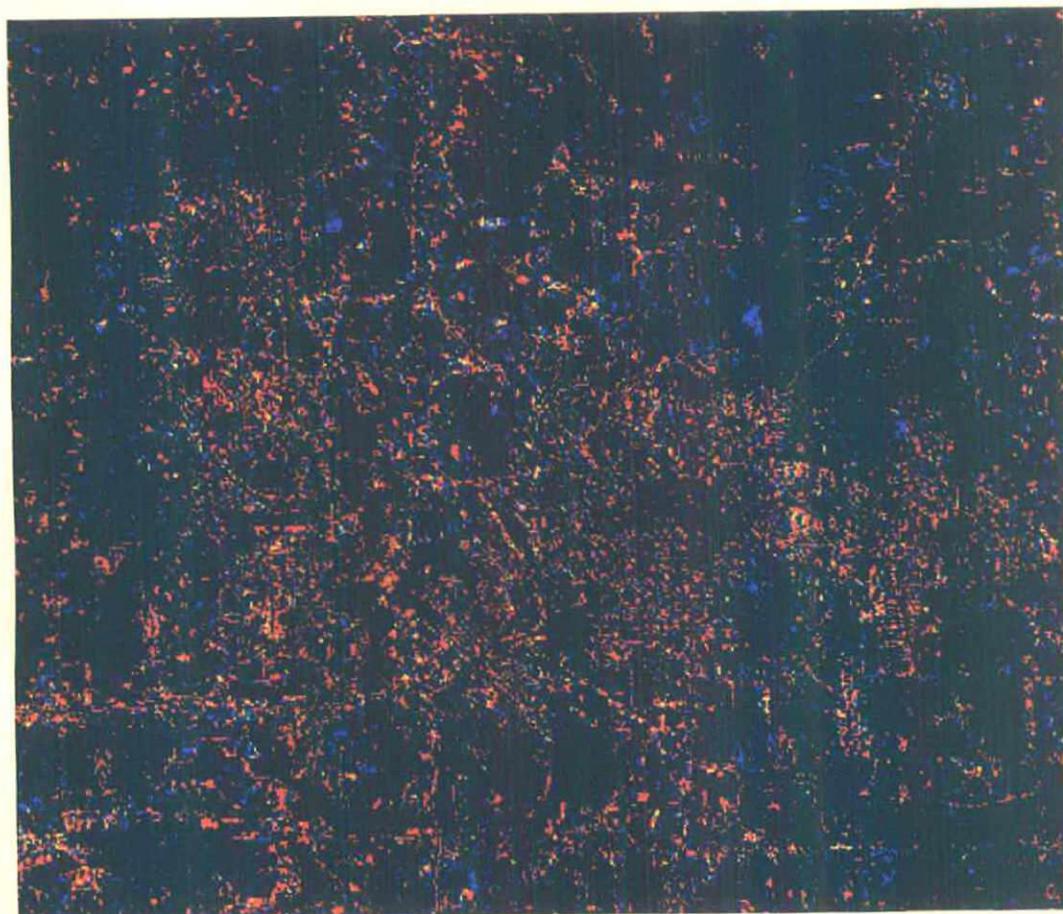


FIGURA 7.21 - Área de Não Mudança - Gramínea / Área Urbana em 1984 e 1988

Classificada: EV84EU88 - 1:100000

■ Vazio ■ EVE84 ■ EUR88 ■ Intersecção

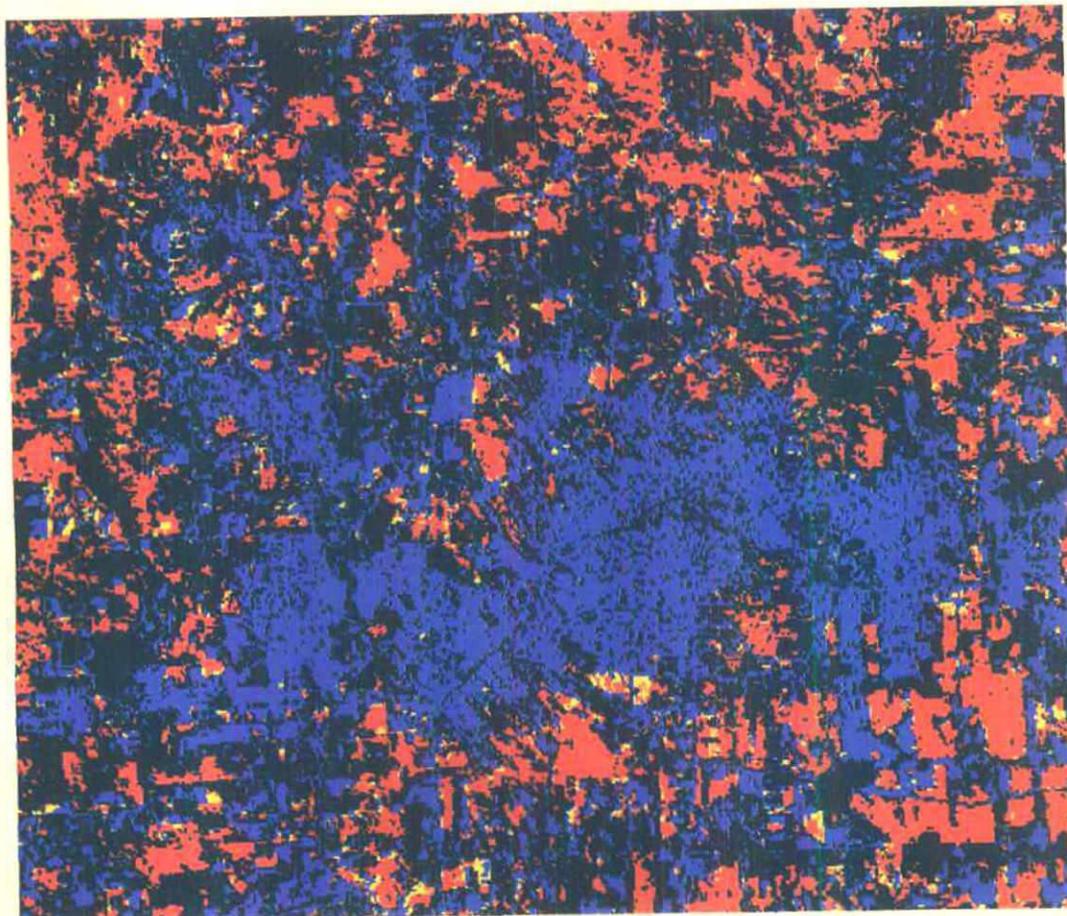


FIGURA 7.22 - Área de Mudança - Vegetação em 1984 para Área Urbana em 1988

Classificada: EM84EU88 - 1:100000

■ Vazio ■ EMI84 ■ EUR88 ■ Intersecção

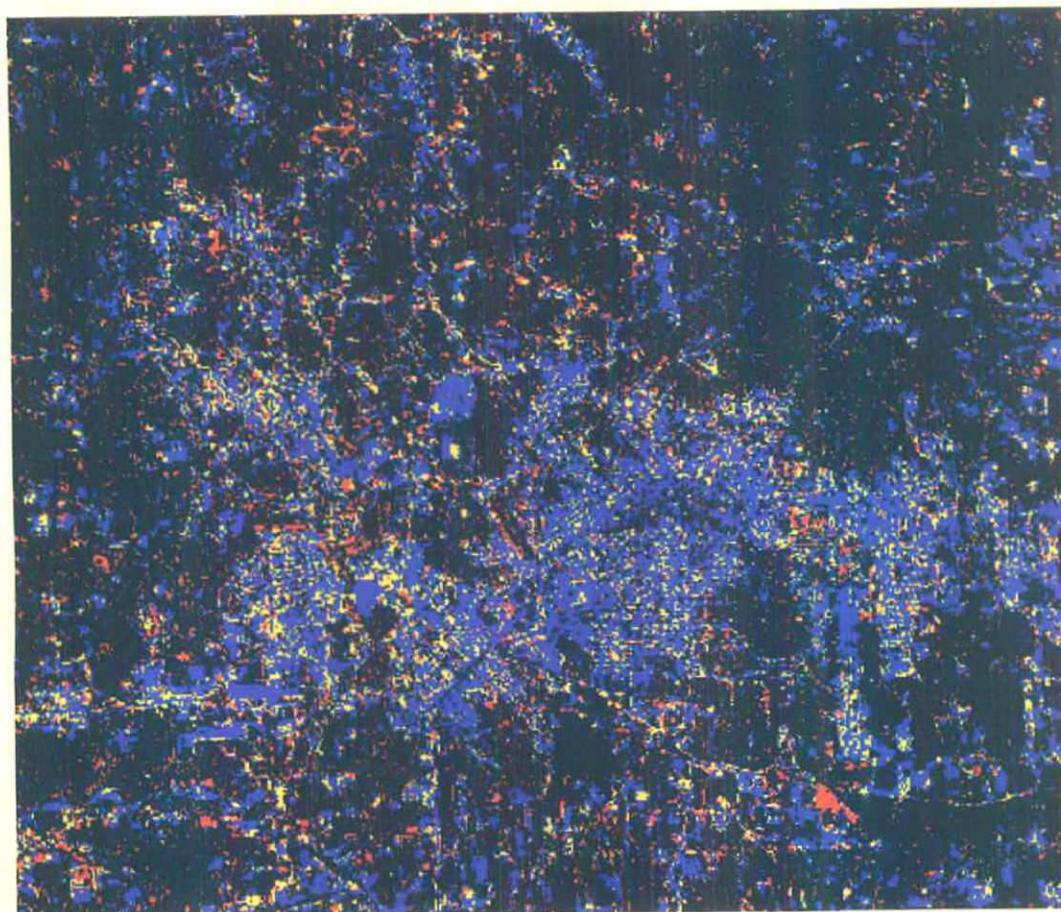


FIGURA 7.23 - Área de Mudança - Área de Mineração em 1984 para Área Urbana em 1988

Classificada: EP84EU88 - 1:100000

■ Vazio ■ EPA ■ EUR88 ■ Intersecção

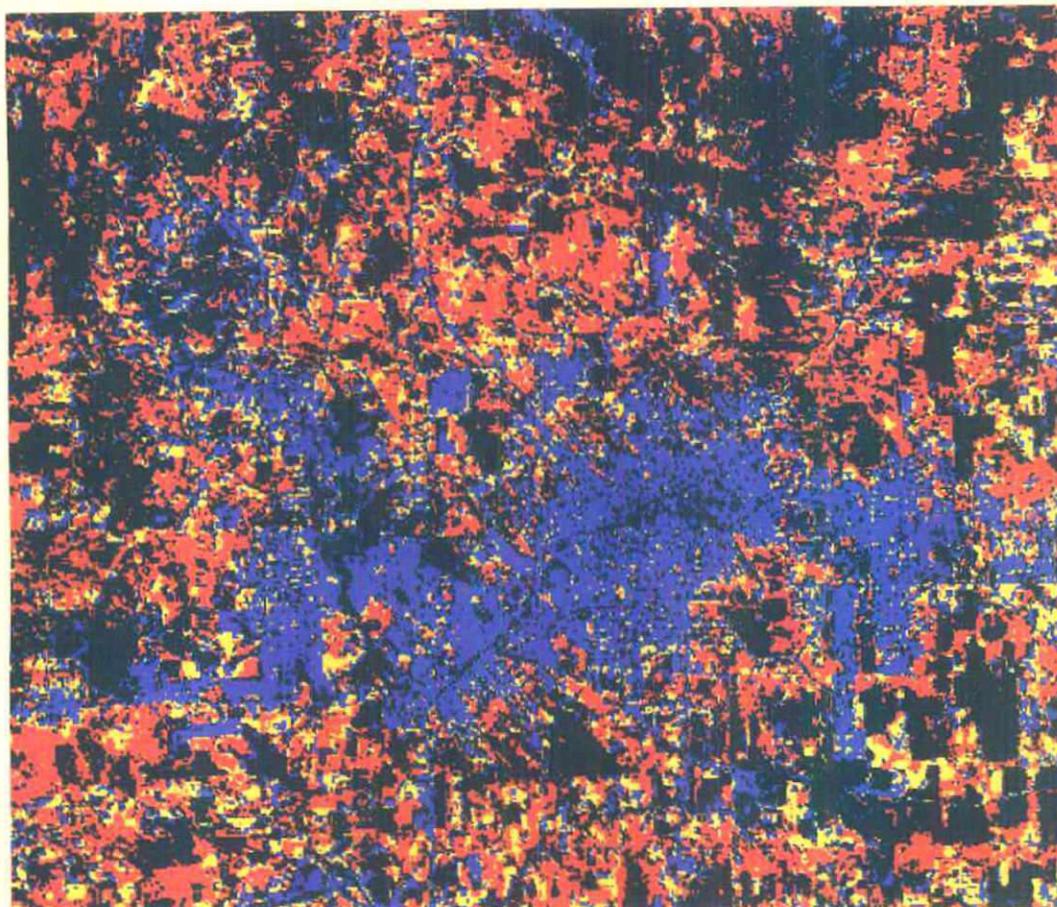


FIGURA 7.24 - Área de Mudança - Gramínea em 1984 para Área Urbana em 1988

7.5 Desempenho do Classificador Difuso

Como já citado, existem diversos métodos para a classificação de imagens digitais. A filosofia adotada por esses métodos pode-se resumir na definição de uma função discriminante a partir de hiperplanos. Entre os vários procedimentos de classificação que adotam o enfoque probabilístico, o classificador de máxima verossimilhança, é o que produz funções de perda (associadas a más classificações) mínimas (BEZDEK, 1987, JOHNSON e WICHERN, 1988).

O classificador difuso proposto neste trabalho, baseia-se no classificador de máxima verossimilhança.

Em termos de parâmetros, o classificador difuso utiliza os conceitos de vetor de médias difusas e matriz de covariâncias difusa. O cálculo desses valores é efetuado de acordo com as equações (5.5) e (5.6) apresentadas no capítulo 5.

Para estimar as pertinências dos pixels na amostra, utiliza-se a função densidade normal multivariada, conforme descrito em 5.3.2, e o resultado obtido constitui-se em uma partição do espaço espectral.

Como o objetivo do desenvolvimento do classificador difuso foi sanar uma deficiência dos classificadores tradicionais, que não conseguem identificar as misturas entre classes, e ele foi desenvolvido com base numa função discriminante derivada da utilizada no classificador de máxima verossimilhança, não existe a preocupação de que seu desempenho, em termos de precisão de classificação, seja melhor que esse último. Entretanto, o que se espera é que, em termos estatísticos, os dois métodos de classificação não difiram nesse aspecto.

Para demonstração foi utilizada a imagem de 03/05/1984 de Criciúma (FIGURA 7.6)

Aplicando-se o classificador de máxima verossimilhança nessa imagem obtêm-se os resultados apresentados nas TABELAS 7.5, 7.6 e 7.7,

correspondendo às áreas de cada classe, o desempenho do classificador e a matriz confusão, respectivamente.

TABELA 7.5 - Áreas das Classes - Classificador de Máxima Verossimilhança

Classes	Área (Km ²)
Banana	3.97
Área de Mineração	3.47
Gramínea	60.02
Área Urbana	29.17
Vegetação	32.98
Total	129.60

TABELA 7.6 - Desempenho do Classificador de Máxima Verossimilhança

Desempenho Médio	92.870 %
Abstenção Média	5.946 %
Confusão Média	1.184 %

TABELA 7.7 - Matriz-Confusão - Classificador de Máxima Verossimilhança

Classes	Banana	Área de Min.	Pasto	Área Urbana	Vegetação	Mistura	Outras
Banana	96.00	0.0	0.44	0.0	0.0	0.0	3.56
Área de Min.	0.0	94.95	0.0	0.66	0.0	0.0	4.40
Gramínea	0.11	0.0	92.87	1.70	0.0	0.0	5.32
Área Urbana	0.0	0.41	1.54	92.50	0.41	0.0	5.14
Vegetação	0.0	0.0	0.16	0.0	91.45	0.0	7.99

A imagem classificada através do algoritmo difuso, adotando-se um nível alfa de 0.5, conduziu aos resultados apresentados nas TABELAS 7.8, 7.9 e 7.10.

TABELA 7.8 - Áreas das Classes - Classificador Difuso

Classes	Área (Km ²)
Banana	3.59
Área de Mineração	3.34
Gramínea	57.97
Área Urbana	26.44
Vegetação	31.44
Total	122.78

TABELA 7.9 - Desempenho do Classificador Difuso

Desempenho Médio	91.912 %
Abstenção Média	6.918 %
Confusão Média	1.170 %

TABELA 7.10 - Matriz-Confusão - Classificador Difuso

Classes	Banana	Área de Min.	Pasto	Área Urbana	Vegetação	Mistura	Outras
Banana	95.56	0.0	0.44	0.0	0.0	0.0	4.0
Área de Min.	0.0	94.07	0.0	0.22	0.0	0.0	5.71
Gramínea	0.11	0.0	91.86	1.47	0.0	0.23	6.33
Área Urbana	0.0	0.31	1.64	91.06	0.41	0.51	6.06
Vegetação	0.0	0.0	0.16	0.0	91.14	0.0	8.70

Os coeficientes Kappa obtidos tanto para o classificador de máxima verossimilhança quanto para o classificador difuso são apresentados na TABELA 7.11.

TABELA 7.11 - Coeficientes Kappa para os Classificadores Utilizados

Classe	Máxima	Classificador
	Verossimilhança	Difuso
Banana	0.9575	0.9528
Área de Min.	0.9429	0.9159
Gramínea	0.9088	0.8779
Área Urbana	0.9011	0.8828
Vegetação	0.8882	0.8726
Global	0.9071	0.8882

Da análise das tabelas anteriores, verifica-se um elevado grau de associação entre os resultados. Foi calculado o coeficiente de correlação entre as áreas (TABELAS 7.5 e 7.8), obtendo-se um valor de 0.9994. Para as percentagens de acertos (TABELAS 7.6 e 7.9) o coeficiente de correlação obtido foi 0.9881 e entre os coeficientes Kappa (TABELA 7.11) foi 0.9935.

Para testar a hipótese de que os valores de áreas, percentual de acertos e coeficientes diferem significativamente entre os classificadores, evidenciando desse modo diferenças quanto aos resultados produzidos por eles, testes t foram realizados. Os resultados encontram-se na TABELA 7.12.

TABELA 7.12 - Estatísticas t para Diferenças

Diferença Testada	Estatística t	Graus de Liberdade	Significância
Áreas Estimadas	0.0935	7.989	0.464
Percentual de Acertos	0.7538	7.879	0.236
Valores Coeficientes Kappa	0.5375	7.921	0.303

Todas as diferenças testadas não se mostram significativas, denotando não existir diferenças entre os resultados obtidos pelos dois classificadores. Contudo, o algoritmo proposto apresenta a vantagem de juntamente com a classificação, fornecer informações sobre pixels mistura presentes na imagem.

Para demonstrar a capacidade do algoritmo proposto para identificação de pixels mistura, uma imagem sintética, contendo três classes, foi gerada a partir de dados reais (JENSEN, 1986). A imagem é apresentada na FIGURA 7.25.

Foram extraídos dois conjuntos de amostras. O primeiro conjunto foi utilizado durante o processo de classificação e para verificação de desempenho. O outro foi utilizado como área teste para verificação do desempenho dos métodos de classificação.

A TABELA 7.13 apresenta a classificação das áreas de treinamento - amostra 1- utilizando o algoritmo de máxima verossimilhança, com limiar de 99% e o classificador difuso, com diversos valores para o nível α . Na TABELA 7.14, é apresentado o desempenho dos algoritmos utilizando-se a amostra 2.

Composição RGB: 123 - 1:10000

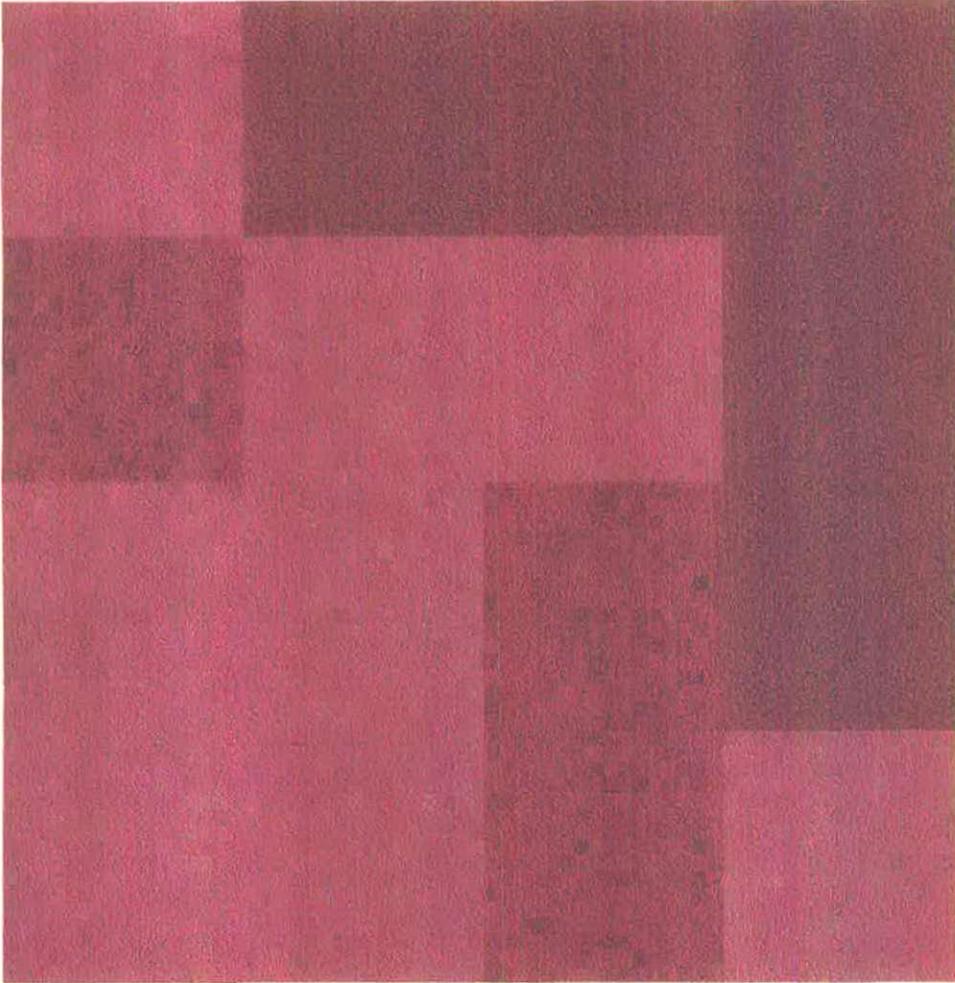


FIGURA 7.25 - Imagem Sintética - Composição Colorida

TABELA 7.13 - Desempenho dos Classificadores - Amostra 1

Algoritmo	Classe	c1	c2	c3	Mistura	Outras
Max.Ver.	c1	100.0	0.0	0.0	-	0.0
Difuso $\alpha = 0.5$		100.0	0.0	0.0	0.0	0.0
$\alpha = 0.6$		100.0	0.0	0.0	0.0	0.0
$\alpha = 0.7$		100.0	0.0	0.0	0.0	0.0
$\alpha = 0.8$		98.80	0.0	0.0	1.20	0.0
$\alpha = 0.9$		93.98	0.0	0.0	6.02	0.0
$\alpha = 1.0$		0.0	0.0	0.0	100.0	0.0
Max.Ver.	c2	2.41	97.59	0.0	-	0.0
Difuso $\alpha = 0.5$		2.41	97.59	0.0	0.0	0.0
$\alpha = 0.6$		2.41	97.59	0.0	0.0	0.0
$\alpha = 0.7$		1.20	97.59	0.0	1.20	0.0
$\alpha = 0.8$		1.20	97.59	0.0	1.20	0.0
$\alpha = 0.9$		1.20	97.59	0.0	1.20	0.0
$\alpha = 1.0$		0.0	97.59	0.0	2.41	0.0
Max.Ver.	c3	0.0	0.0	98.81	-	1.19
Difuso $\alpha = 0.5$		0.0	0.0	98.81	0.0	1.19
$\alpha = 0.6$		0.0	0.0	98.81	0.0	1.19
$\alpha = 0.7$		0.0	0.0	98.81	0.0	1.19
$\alpha = 0.8$		0.0	0.0	98.81	0.0	1.19
$\alpha = 0.9$		0.0	0.0	98.81	0.0	1.19
$\alpha = 1.0$		0.0	0.0	98.81	0.0	1.19

Examinando-se os resultados da TABELA 7.13, fica evidenciado que:

- o algoritmo de máxima verossimilhança não consegue identificar os pixels mistos;
- os níveis α adotados para a classificação das imagens, que representam critérios de precisão requeridos para a identificação dos pixels, influenciam no resultado da classificação;

- todos os pixels da classe c1 apresentam-se misturados, mas, à medida que o critério é relaxado, grande parte dos pixels da classe c1 passam a ser classificados unicamente nessa classe;

- na classe c2, 97.59% dos pixels amostrados são puros. O algoritmo de máxima verossimilhança identifica o restante dos pixels como sendo classe c1, enquanto que o algoritmo difuso os identifica como mistos;

- na classe c3 não ocorre mistura, mas, sim, a existência de pixels representativos de classes não consideradas no processo de classificação. Esse resultado é confirmado nos dois algoritmos utilizados.

TABELA 7.14 - Desempenho dos Classificadores - Amostra 2

Algoritmo	Classe	c1	c2	c3	Mistura	Outras
Max.Ver.	c1	97.28	2.04	0.0	-	0.68
Difuso $\alpha = 0.5$		97.28	1.36	0.0	0.68	0.68
$\alpha = 0.6$		97.28	1.36	0.0	0.68	0.68
$\alpha = 0.7$		97.28	1.36	0.0	0.68	0.68
$\alpha = 0.8$		94.56	1.36	0.0	3.40	0.68
$\alpha = 0.9$		89.80	1.36	0.0	8.16	0.68
$\alpha = 1.0$		0.0	1.36	0.0	97.96	0.68
Max.Ver.		c2	5.21	92.71	0.0	-
Difuso $\alpha = 0.5$	5.21		92.71	0.0	0.0	2.08
$\alpha = 0.6$	5.21		92.71	0.0	0.0	2.08
$\alpha = 0.7$	5.21		92.71	0.0	0.0	2.08
$\alpha = 0.8$	5.21		92.71	0.0	0.0	2.08
$\alpha = 0.9$	5.21		92.71	0.0	0.0	2.08
$\alpha = 1.0$	0.0		92.71	0.0	5.21	2.08
Max.Ver.	c3		0.0	0.0	98.53	0.0
Difuso $\alpha = 0.5$		0.0	0.0	98.53	0.0	1.47
$\alpha = 0.6$		0.0	0.0	98.53	0.0	1.47
$\alpha = 0.7$		0.0	0.0	98.53	0.0	1.47
$\alpha = 0.8$		0.0	0.0	98.53	0.0	1.47
$\alpha = 0.9$		0.0	0.0	98.53	0.0	1.47
$\alpha = 1.0$		0.0	0.0	98.53	0.0	1.47

Avaliando-se o desempenho dos algoritmos de classificação na área de treinamento do conjunto 2, verifica-se um resultado global semelhante ao anterior. Contudo, é interessante notar que, para os pixels amostrados como sendo classe c1, existe a presença de pixels puros da classe c2. O algoritmo de máxima verossimilhança identifica-os, porém, com o acréscimo daqueles que apresentam mistura de classes.

7.6 Conclusão

Os resultados obtidos, das diferentes aplicações, demonstram a vantagem de trabalhar-se com as informações obtidas com a utilização do classificador difuso.

As aplicações apresentadas consistem de alguns casos em que se considera importante a utilização da abordagem usando conjuntos difusos. Entretanto, sabe-se que não esgotam o assunto: em qualquer tipo de estudo em que a identificação da mistura entre classes seja importante, poderá ser utilizado o classificador difuso desenvolvido.

8. CONCLUSÕES E RECOMENDAÇÕES

8.1 Conclusões

O processamento digital de imagens obtidas por sensores orbitais tem assumido importância crescente nos últimos anos, como uma forma eficiente para o mapeamento da cobertura terrestre. Inúmeras pesquisas têm sido realizadas na busca de técnicas adequadas para análise, visando às mais variadas aplicações. Particularmente, um grande número de pesquisas têm sido realizadas, na busca de técnicas e procedimentos adequados para a discriminação dos tipos de cobertura de regiões.

Os classificadores tradicionais baseiam-se na teoria clássica dos conjuntos. Esses classificadores, porém, apresentam dificuldades na identificação de pixels mistos ou intermediários, tendo em vista que, devido a características espectrais, é possível que eles sejam classificados em mais de uma classe. Além disso, utilizam uma função discriminante com diferentes valores para as diferentes classes, mas, em termos de decisão, atribuem o pixel a uma única classe, não considerando informações sobre a evidência de pertencerem a outras classes.

A teoria dos conjuntos difusos permite modelar situações onde a imprecisão tem origem no fato de os conjuntos não possuírem limites bem definidos. Dada a imprecisão existente para a caracterização desses limites, um elemento pode pertencer simultaneamente a mais de um conjunto. A intensidade com que o elemento participa do conjunto denomina-se grau de pertinência. Essa característica da teoria dos conjuntos difusos pode ser aplicada no processo de classificação de imagens digitais, para tratar o problema da presença de pixels mistos ou intermediários, reduzindo-se assim a perda de informação associada a classificações dicotômicas.

Nesse contexto, é possível modelar as classes como conjuntos difusos, sendo os pixels seus elementos. Quando existe evidência da presença de mais de uma classe numa determinada área, o pixel pode pertencer parcialmente a essas classes, tornando-se, portanto, necessário a utilização de

uma partição difusa do espaço espectral. De acordo com esse conceito, os pixels possuem pertinência em várias classes.

Apresenta-se, neste trabalho, um classificador difuso, o qual, a partir de amostras fornecidas para as classes, determina primeiramente uma partição difusa do espaço espectral, realizando, posteriormente, a classificação propriamente dita. O classificador baseia-se em expressões analíticas de densidades multivariadas para avaliar a pertinência de cada pixel às classes.

O conceito de partição difusa do espaço espectral é fundamental nesse trabalho. É a partir dele que se processa a classificação da imagem e outras informações relevantes para o processamento digital de imagens são deduzidas. Essas informações são representadas através de imagens de pertinência, permitindo sua utilização em processos de tomada de decisão em ambientes difusos. Para suporte computacional deste trabalho, foi desenvolvido e implementado um sistema para tratamento, processamento e classificação de imagens digitais, o qual incorpora esse conceito e outros dele derivados.

Como já referido, um problema existente nos métodos tradicionais é a atribuição dicotômica dos pixels às classes. A partir dos resultados obtidos pelo processo de classificação desenvolvido neste trabalho, esse problema é ultrapassado. Realizando-se um corte de nível alfa em cada um dos conjuntos que representam as classes, e atribuindo uma cor a cada classe, é possível visualizar o resultado da classificação para um nível de veracidade alfa. Nessa imagem, os pixels onde ocorre mistura de classes são de fácil identificação.

O algoritmo de classificação proposto introduz o conceito de limiar para o valor de pertinência durante o processo de classificação, reduzindo, consideravelmente, a possibilidade de obtenção de classificações erradas.

A criação de imagens de pertinência permite um tratamento sistematizado da imagem digital que se está analisando. Após uma mudança de escala dos valores de pertinência, é possível visualizar os valores de pertinência calculados como diferentes níveis de cinza. Além dessa visualização, as imagens de pertinência podem ser utilizadas em rotinas de manipulação e armazenamento da mesma forma que as bandas espectrais.

Um resultado importante obtido são as imagens classificadas a um nível alfa. Nessas imagens, tem-se o grau mínimo de veracidade ou possibilidade de que o pixel pertença à classe na qual está representado. Essa representação permite identificar os pixels que, a um determinado nível de possibilidade, constituem mistura de classes. Na implementação computacional, foi reservada a cor branca para esses pixels. Com relação aos graus de pertinência, esses variam em termos de diferentes graus de cinza.

Sistemas computacionais direcionados ao processamento digital de imagens apresentam problemas relacionados ao custo do hardware necessário e à complexidade das rotinas que devem ser implementadas. O sistema EDIMA foi desenvolvido em uma plataforma do tipo PC, extremamente difundida no mercado e de custos de hardware acessíveis. Em termos de interface, o sistema EDIMA utiliza os recursos do ambiente Windows, sendo, conseqüentemente, extremamente amigável. As funções implementadas constituem-se num núcleo central de um sistema de processamento de imagens. A introdução do método de classificação difusa torna o sistema uma alternativa promissora aos sistemas existentes.

As aplicações apresentadas consistem de alguns casos em que se considera importante a utilização da abordagem usando conjuntos difusos.

Problemas de identificação de metaclasses, um conceito introduzido neste trabalho, são resolvidos com as informações difusas obtidas. Para tanto, um método de classificação utilizando similaridade contextual difusa para determinação de padrões de classes de uso do solo foi aplicado. Esse método, apresentado no capítulo 5, desenvolve-se em dois estágios: classificação difusa e determinação da similaridade contextual difusa. Os resultados obtidos na área teste evidenciam que a abordagem proposta é bastante promissora na identificação de áreas em que existam classes de uso do solo formadas por elementos com respostas espectrais diferentes.

Análises multitemporais são importantes no estudo de áreas urbanas. A análise do crescimento ocorrido permite, por exemplo, identificar as áreas que estão sendo ocupadas pela expansão urbana. Através de manipulações sobre composições coloridas de imagens classificadas pelo algoritmo difuso e pelo uso do conceito de imagens de pertinência, foi possível realizar um estudo sobre a expansão verificada na área teste, definida sobre uma

imagem do município de Criciúma - SC, entre os anos de 1984 e 1988. Com os resultados obtidos, foi possível identificar esse crescimento. Em termos de detecção de mudanças, as informações contidas nas imagens de pertinência e na banda extraída da imagem classificada, resultantes do algoritmo difuso para classificação de imagens, permitiram identificar os movimentos havidos entre áreas urbanas e as demais classes, dentro do período citado.

Finalmente, um estudo comparativo entre o algoritmo proposto e o algoritmo de máxima verossimilhança para classificação de imagens digitais foi realizado. Através desse estudo, concluiu-se que a precisão da classificação dos dois algoritmos não difere significativamente. Entretanto, o algoritmo difuso tem a vantagem de identificar as áreas de mistura entre as classes, como proposto.

8.2 Recomendações

O algoritmo proposto para classificação de imagens digitais obtidas através de sensoriamento remoto permitiu o tratamento de informações que não são consideradas por outros classificadores. As aplicações apresentadas não esgotam o assunto. Em qualquer tipo de estudo em que a identificação de mistura entre classes seja importante, o mesmo poderá ser utilizado.

Uma melhoria no algoritmo difuso proposto poderá ser obtida com o estabelecimento de novos mecanismos de avaliação de pertinências nos pixels amostrados nas áreas de treinamento.

A aplicação do algoritmo difuso apresentado não se restringe a problemas de classificação de imagens digitais. A exemplo do algoritmo de máxima verossimilhança, pode ser aplicado a qualquer problema de classificação de populações. É especialmente aplicável a situações, nas quais existam imprecisões derivadas de processos cognitivos, percepção e julgamento humano.

A integração do sistema EDIMA em um sistema de informações geográficas é também tema para futuros desenvolvimentos.

Uma outra alternativa para a classificação de imagens digitais a ser investigada é o uso de redes neurais para a classificação das imagens. Redes neurais tem a capacidade de desenvolver uma representação interna de um padrão que lhe seja fornecido como entrada. A cada um dos processadores que compõem a rede existe um peso associado, que faz com que a representação interna do padrão seja feita pelo ajustamento dinâmico dos pesos associados a cada processador, no momento em que o padrão é fornecido à rede. Redes neurais apresentam importantes características para o processo de classificação, porque são tolerantes aos desvios que possam ocorrer nos padrões e são capazes de reconhecer determinados elementos (pixels), mesmo que esses se apresentem distorcidos ou com a falta de algumas características.

BIBLIOGRAFIA

- ADELI, H. Expert Systems in Construction and Structural Engineering. *Artificial Intelligence and Expert Systems*. Chapman and Hall, 1988. p. 1-12.
- AHEARN, Sean C, e WEE, Catherine. Data Space Volumes and Classification Optimization of SPOT and Landsat TM Data. *Photogrammetric Engineering & Remote Sensing*. v. 57, n.1, janeiro 1991. p. 61-65.
- ALMEIDA, Wagner Santos de. Determination of Low Water Line in Brazilian Coasts by Remote Sensing Techniques. *Proceedings of the Twenty-Fourth International Symposium on Remote Sensing of Environment*. Rio de Janeiro, 27-31 maio 1991. v.1. p. 137-145.
- ALVES, Alceu Ribeiro; LAPOLLI, Édís Mafra; GAUTHIER, Fernando A.O. e BARCIA, Ricardo Miranda. Digital Image Processing through Fuzzy Set Theory. *Memórias del 5to Simposio Latinoamericano de Percepción Remota*. Cuzco, Peru, 28 outubro - 01 novembro 1991. p. 491-495.
- ALVES, Alceu Ribeiro; LAPOLLI, Édís Mafra; BASTOS, Rogério Cid e BASTOS, Lia Caetano. Classificação de Imagens Digitais pelo Método da Máxima Verossimilhança: Uma Nova Abordagem. *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. II. p. 281-283.
- ALVES, Alceu Ribeiro; LAPOLLI, Édís Mafra; FRANZONI, Ana Maria B, e LUZ, Victor José P. Integração de Imagens Multiespectral e Pancromática SPOT visando ao Estudo de Áreas Urbanas. *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. I. p. 001-006.
- ALVES, José Luiz. Cadastro Urbano e de Áreas de Expansão Urbana. *Anais do 1º Seminário Nacional de Cadastro Técnico Rural e Urbano*. Curitiba, 9-12 fevereiro 1987. p. 39-52.
- AMARAL, Gilberto. Princípios de Sensoriamento Remoto. *Anais do Simpósio Brasileiro de Geoprocessamento*. São Paulo, 23-25 de maio de 1990. p.27-36.
- AMARO, V.E.; SÁ, E.F.J; VAUCHEZ, A. e DUARTE, M.I.M. Integração e Análise de Imagens Multiespectrais na Melhoria da Interpretação Geotectônica da Província Borborema (NE do Brasil): *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. III. p. 148-151.
- ANDREWS, Harry C. *Introduction to Mathematical Techniques in Pattern Recognition*. New York, Wiley-Interscience, 1972. 242 p.
- ANNONI, A.; VENTURA, A. Della; MOZZI, E. e SCHETTINI, R. Towards the Integration of Remote Sensing Images Within a Cartographic System. *Computer-aided Design*. v. 22, n. 3, abril 1990, p. 158-166.

- ARARIBÓIA, G. *Inteligência Artificial. Um Curso Prático*. Rio de Janeiro, Livros Técnicos e Científicos, 1988. 282p.
- ARGIALAS, Demetre P. e NARASIMHAN, Ravi. TAX: Prototype Expert System for Terrain Analysis. *Journal of Aerospace Engineering*. v. 1, n. 3, julho 1988. p. 151-171.
- ARGIALAS, Demetre P. e HARLOW, Charles A. Computational Image Interpretation Models: an Overview and a Perspective. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 6, junho 1990. p. 871-886.
- ARONOFF, Stan. Classification Accuracy: A User Approach. *Photogrammetric Engineering & Remote Sensing*. v. 48, n. 8, agosto 1982. p. 1299-1307.
- BAILEY, M.A. The Structure of the Urban Landscape. *Proceedings of the First Australasian Landsat Conference*. Sidney, 1979.
- BAIRD, Henry S. Feature Identification for Hybrid Structural/Statistical Pattern Classification. *Computer Vision, Graphics, and Image Processing*. v. 42, n. 3, junho 1988. p. 318-333.
- BALDWIN, J. F. Fuzzy Sets and Expert Systems. *Information Sciences*. v. 36, 1985. p. 123-156.
- BARR, Avron e FEIGENBAUM, Edward A. *The Handbook of Artificial Intelligence*. Reading, Addison-Wesley, 1986. 409p.
- BASSAT, Moshe Ben e TEENI, Dov. Human - Oriented Information Acquisition in Sequential Pattern Classification: Part I - Single Membership Classification. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 14, n. 1, janeiro-Fevereiro 1984. p. 131-138.
- BATISTA, Leonardo Vidal e FINAMORE, Weiler Alves. Análise Comparativa de Técnicas de Classificação Automática de Imagens de Satélite. *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. II. p. 291-295.
- BERGADANO, F.; GIORDANA, A. e SAITTA, L. Knowledge Representation and Use in Pattern Analysis. *Information Sciences*. v. 47, 1989. p. 1-16.
- BEZDEK, J. C. *Pattern Recognition with Fuzzy Objective Function Algorithms*. 2. ed. New York, Plenum Press, 1987. 256p.
- BIALASIEWICZ, Jan. Sufficient and E-Sufficient Statistics in Pattern Recognition and their Relation to Fuzzy Techniques. *IEEE Transactions on Systems, Man and Cybernetics*. v. 19, n. 5, setembro-outubro 1989. p. 1261-1263
- BIERWIRTH, P.N., LEE, T.J. e BURNE, R.V. Shallow Sea-Floor Reflectance and Water Depth Derived by Unmixing Multispectral Imagery. *Photogrammetric Engineering & Remote Sensing*. v. 59, n. 3, março 1993. p.331-338.

- BIRCH, Martin e WHITELET, Keith. An Object-Oriented Expert System Based on Pattern Recognition. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 20, n. 1, janeiro-fevereiro 1990. p. 33-44.
- BIRKHOLZ, Lauro Bastos. Evolução do Conceito de Planejamento Territorial. *Questões de Organização do Espaço Regional*. São Paulo, Nobel, 1983. p. 1-24.
- BISWAS, Prasenjit e MAJUMDAR, Arun K. *A Fuzzy Hybrid Discrete Multivariate Analysis. Theory and Practice*. Londres, The MIT Press, 1988. 557 p.
- BISHOP, Y.M.M.; FIENBERG, S.E. e HOLLAND, P.W. Model for Pattern Classification. *Proceedings of the 4th International Conference on Pattern Recognition*. Cambridge, 1988. p. 183-192.
- BODEN, M. *Artificial Intelligence and Natural Man*. Harvester Press, 1977. 537p.
- BOLDT, Michael; WEISS, Richard e RISEMAN, Edward. Token-Based Extraction of Straight Lines. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 19, n. 6, novembro-dezembro 1989. p. 1581-1594.
- BOLSTAD, Paul V. e LILLESAND, T. M. Rapid Maximum Likelihood Classification. *Photogrammetric Engineering & Remote Sensing*. v. 57, n. 1, janeiro 1991. p. 67-74.
- BOOCH, G. *Object Oriented Design with Applications*. The Benjamin/Wmings Publishing Company, 1991. 580 p.
- BOUCHON, Bernadette. *On the Forms Reasoning in Expert Systems. Approximate Reasoning in Expert Systems*. North Holland, 1985. p. 341-354.
- BOUCHON, Bernadette e DESPRES, Sylvie. Propagation of Uncertainties and Inaccuracies in Knowledge-Based System. Uncertainty in Knowledge - Based Systems. *Proceedings of the International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems*. Paris, 1986. p. 58-65.
- BOZINOVSKI, Stevo. A Representation Theorem for Linear Pattern Classifier Training. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 15, n. 1, janeiro-fevereiro 1985. p. 159-161.
- BRANCH, M. C. *City Planning and Aerial Information*. Cambridge, Harvard Press, 1971.
- BRANDT, Robert D.; WANG, Yao; LAUB, Alan J. e MITRA, Sanjit K. The Recognition of Shapes in Binary Images Using a Gradient Classifier. *IEEE Transactions on Systems, Man and Cybernetics*. v. 19, n. 6, novembro-dezembro 1989. p. 1595-1599.

- BRUM, Enéas Rodrigues. *Integração dos Canais Multiespectrais e Pancromáticos do Sensor HRV (SPOT) para Obtenção de Composições Coloridas com Resolução Espacial Próxima a 10 m*. Dissertação de Mestrado. Instituto Nacional de Pesquisas Espaciais, 1989. 98 p.
- BRUNA, Gilda Collet. Planejamento de Áreas Urbanas e Rurais. *Questões de Organização do Espaço Regional*. São Paulo, Nobel, Ed. da Universidade de São Paulo, 1983. p. 225-250.
- BUCHHEIM, Martin P. e LILLESAND, Thomas M. Semi-Automated Training Field Extraction and Analysis for Efficient Digital Image Classification. *Photogrammetric Engineering & Remote Sensing*. v. 55, n. 9, setembro 1989. p. 1347-1355.
- BUCK, Thomas de Araujo e NETTO, Márcio L. de Andrade. Reconhecimento de Padrões através de Máscaras Nebulosas. *Revista de Informática Teórica e Aplicada*. v. 1, n. 2, maio 1990. p. 37-43.
- BURROUGH, P. A. *Principles of Geographical Information Systems for Land Resources Assessment*. Oxford, Clarendon Press, 1987. 194p.
- CAMPBELL, William J. e CROMP F. Evolution of an Intelligent Information Fusion System. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 6, junho 1990. p. 867-870.
- CARD, Don H. Using Known Map Category Marginal Frequencies to Improve Estimates of Thematic Map Accuracy. *Photogrammetric Engineering & Remote Sensing*. v. 48, n. 3, março 1982. p. 431-439.
- CARDIERI, F.L. ; ROSA, F. S. e BUSCHEL, E. C. G.. Monitoramento de Expansão Urbana na Região Metropolitana de São Paulo. *Anais do V Simpósio Brasileiro de Sensoriamento Remoto*. Natal, 11-15 outubro 1988. v. 1. p. 022-030.
- CARDIERI, F.L. e NASCIMENTO, I. A Avaliação do Uso e Ocupação do Solo da Região Metropolitana de São Paulo. *Anais do V Simpósio Brasileiro de Sensoriamento Remoto*. Manaus, 24-29 junho 1990. v. 2. p. 426-431.
- CARNOTA, Raúl Jorge e TESKIEWICZ, Alberto Daniel. *Sistemas Expertos y Representación del Conocimiento*. Tandil, Kapelusz, 1988. 240p.
- CARPER, W.J.; LILLESAND, T.M. e KIEFER. The Use of Intensity-Hue-Saturation Transformations for Merging SPOT Panchromatic and Multispectral Image Data. *Photogrammetric Engineering & Remote Sensing*. v. 56, n.4, abril 1990. p. 459-467.
- CARR, James R.; GLASS, Charles E. e SCHOWENGERDT, Robert A. Signature Extension Versus Retraining for Multispectral Classification of Surface Mines in Arid Regions. *Photogrammetric Engineering & Remote Sensing*. v. 49, n. 8, agosto 1983. p. 1193-1199.

- CARRARA, Ana Lúcia Ramos; FORESTI, Celina e SANTOS, João Roberto dos. A Distribuição dos Espaços Verdes em Áreas Urbanas: Cartografia e Análise Comparativa entre Dados TM/LANDSAT e HRV/SPOT. *Anais do II Encontro Nacional de Sensoriamento Remoto Aplicado ao Planejamento Municipal*. Serra Negra, 2-5 abril 1991. p. 11-23.
- CENTENO, Jorge A. Silva e HAERTEL, Vitor. Application of Contextual Classification to Land-Cover Mapping in Watersheds. *Proceedings of the Twenty-Fourth International Symposium on Remote Sensing of Environment*. Rio de Janeiro, 27-31 maio 1991. v.I, p. 171-181.
- CENTENO, Jorge A. Silva e HAERTEL, Vitor. Classificação Contextual de Imagens Multiespectrais. *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. II. p. 328-329.
- CETIN, Haluk e LEVANDOWSKI, Donald W. Interactive Classification and Mapping of Multi-Dimensional Remotely Sensed Data Using n-Dimensional Probability Density Functions (nPDF). *Photogrammetric Engineering & Remote Sensing*. v. 57, n.12, dezembro 1991. p. 1579-1587.
- CHANDA, B.; CHAUDHURI, B. B. e MAJUMDER, D. D. A Differentiation/Enhancement Edge Detector and Its Properties. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 15, n. 1, janeiro-Fevereiro 1985. p. 162-168.
- CHAVES JR, Pat S. e KWARTENG, Andrew Yaw. Extracting Spectral Contrast in Landsat Thematic Mapper Image Data Using Selective Principal Component Analysis. *Photogrammetric Engineering & Remote Sensing*. v. 55, n. 3, março 1989. p. 339-348.
- CHAVEZ, P.S., SIDES, S.C. e ANDERSON, J.A. Comparison of Three Different Methods to Merge Multiresolution and Multispectral Data: Landsat TM and SPOT Panchromatic. *Photogrammetric Engineering & Remote Sensing*. v. 57, n. 3, março 1991. p. 295-303.
- CHEN, C. H. Pattern Recognition and Artificial Intelligence. *Proceedings of the Joint Workshop on Pattern Recognition and Artificial Intelligence*. Massachusetts, 1976.
- CHEN, Chi-farn e CHEN, A.J. Change Detection Monitoring by Classification of Combined Temporal-Spectral Remotely Sensed Data. *Proceedings of the Twenty-Fourth International Symposium on Remote Sensing of Environment*. Rio de Janeiro, 27-31 maio 1991. v.II, p. 483-488.
- CHUVIECO, Emilio e CONGALTON, Russel G. Using Cluster Analysis to Improve the Selection of Training Statistics in Classifying Remotely Sensed Data. *Photogrammetric Engineering & Remote Sensing*. v. 54, n. 9, Setembro 1988. p. 1275-1281.

- CIVCO, D. Knowledge-Based Land use and Land Cover Mapping. *Proceedings of the Annual Convention of American Society for Photogrammetry and Remote Sensing*. Baltimore, 1989. v.3. p.276-291.
- CLARK, Bill P. Landsat Thematic Mapper Data Production: a History of Bulk Image Processing. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 4, abril 1990. p. 447-451.
- CLEYNENBREUGEL, J. Van; FIERENS, F. e OOSTERLINCK, A. Delineating Road Structures on Satellite Imagery by a GIS-Guided Technique. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 6, junho 1990. p. 893-898.
- CLEYNENBREUGEL, J. Van; FIERENS, F. e OOSTERLINCK, A. Knowledge-Based Road Network Extraction on SPOT Satellite Images. *Proceedings of the 4 th International Conference on Pattern Recognition*, Cambridge, 1988. p. 352-359.
- CLICHE, G.; BONN, F. e TEILLET, P. Integration of the SPOT Panchromatic Channel into its Multispectral Mode for Image Sharpness Enhancement. *Photogrammetric Engineering & Remote Sensing*. v. 51, n. 3, março 1985. p. 311-316.
- COGO, Sandra E. Vielmo. Feições de Textura para Classificação de Imagens. *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. II, p. 339-346.
- CONGALTON, Russell G.; ODERWALD, Richard G. e MEAD, Roy A. Assessing Landsat Classification Accuracy Using Discrete Multivariate Analysis Statistical Techniques. *Photogrammetric Engineering & Remote Sensing*. v. 49, n. 12, dezembro 1983. p. 1671-1678.
- COTTAS, Luiz Roberto. Estudos Geológico-Geotécnicos Aplicados ao Planejamento Urbano de Rio Claro - SP. Tese de Doutorado. Universidade de São Paulo, 1983.
- COURTOIS, P. On Time and Space Decomposition of Complex Structures. *Communications of ACM*. v. 28, n. 6. 1985.
- CRESS, Jill. e DEISTER, Robin R. P. Development and Implementation of a Knowledge-Based GIS Geological Engineering Map Production System. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 11, novembro 1990, p. 1529-1535.
- DARZENTAS, J. Knowledge Modelling in Fuzzy Expert Systems. *Proceedings of the International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems*. Paris, 1986. p. 159-172.

- DATTATREYA, G. R. e KANAL, L. N. Adaptive Pattern Recognition With Random Costs and Its Application to Decision Trees. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 16, n. 2, março-abril 1986. p. 208-218.
- DATTATREYA, G. R. e KANAL, Laveen N. Detection and Smoothing of Edge Contours in Images by One-Dimensional Kalman Techniques. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 20, n. 1, janeiro- fevereiro 1990. p. 159-165.
- DAVIS, J. R. e GRANT, I. W. ADAPT: a Knowledge-based Decision Support System for Producing Zoning Schemes. *Environment and Planning B: Planning and Design*. v. 14, n. 1, janeiro, 1987. p. 53-66.
- DAVIS, J. R. e GRANT, I. W. *Systems Expert Applications to Urban Planning*. Springer-Verlag, 1990. 268p.
- DEVI, Bharathi e SARMA, V. V. S. A Fuzzy Approximation Scheme for Sequential Learning in Pattern Recognition. *IEEE Transactions on Systems, Man, and Cybernetics*. v. SMC-16, n. 5, setembro-outubro 1986. p. 668-679.
- DEVI, Bharathi e SARMA, V.V. Estimation of Fuzzy Membership from Histograms. *Information Sciences*. n. 35, 1985.
- DOMBI, J. Membership Function as an Evaluation. *Fuzzy Sets and Systems*. n. 35, 1990. p. 01-21.
- DOWMAN, I.J.; EBNER, H. e HEIPKE, C. Overview of European Developments in Digital Photogrammetric Workstations. *Photogrammetric Engineering & Remote Sensing*. v. 58, n.1, janeiro 1992. p.51-56.
- DUBOIS, Didier e PRADE, Henri. *Fuzzy Sets and Systems: Theory and Applications*. New York, Academic Press, 1980. 393 p.
- DUGUAY, Claude R. e LEDREW, Ellsworth F. Estimating Surface Reflectance and Albedo from Landsat-5 Thematic Mapper over Rugged Terrain. *Photogrammetric Engineering & Remote Sensing*. v. 58, n. 5, maio 1992. p.551-558.
- DUTTA, Amitava. Reasoning With Imprecise Knowledge in Expert Systems. *Information Sciences*. v. 37, 1985. p. 3-24.
- EERENS, Hermann; CALMON, Miguel; SAPION, Bart; DEVOS, Wim e GOMBEER, Roland. The Integration of Remote Sensing and GIS-Techniques for the Mapping of Land Use and Assessment of Crop Acreages. In: *Proceedings of the Twenty-Fourth International Symposium on Remote Sensing of Environment*. Rio de Janeiro, 27-31 maio 1991. v.2. p. 591-600.
- EGENHOFFER, Max J. e FRANK, Andrew U. LOBSTER: Combining AI and Database Techniques for GIS. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 6, junho 1990. p. 919-926.

- EHLERS, Manfred. Application of SPOT Data for Regional Growth Analysis and Local Planning. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 2, fevereiro 1990. p. 175-180.
- EHLERS, Manfred; EDWARDS, Geoffret e BÉDARD, Yvan. Integration of Remote Sensing With Geographic Information Systems: A Necessary Evolution. *Photogrammetric Engineering & Remote Sensing*. v. 55, n. 11, novembro 1989. p. 1619-1627.
- EKSTRAND, S. Quantification of Chlorophyll "a" in Coastal Waters Using LANDSAT TM. *Proceedings of the Twenty-Fourth International Symposium on Remote Sensing of Environment*. Rio de Janeiro, 27-31 maio 1991. v.2. p. 925-934.
- ELLEFSEN, R.; GAYSOS, L.; SWAIN, P. e WRAY, J. New Techniques in Mapping Urban Land Use and Monitoring Change for selected U. S. Metropolitan Areas, an Experiment Employing Computer Assisted Analysis of ERTS-1 MSS Data. *Proceedings of the Symposium on Remote Sensing and Photo Interpretation*. Banff, 1974. p. 51-63.
- ELPHINSTONE, A. C.; HERON, A. P.; HOBSON, G.S.; HOUGHTON, A.; LAU, M. K.; POWELL, A.R.; SEED, L. e TOZER, R. C. RAPAC: a High-Speed Image-Processing System. *IEE Proceedings-E*. v. 134, n. 1, janeiro 1987.
- ENGESPAÇO INDÚSTRIA E COMÉRCIO LTDA. *SITIM 150 - Sensoriamento Remoto. Manual do Usuário. Versão 2.2.* 1986.
- ERB, R. B. ERTS 1. Urban Land Use Analysis. *ERTS 1 Investigation*. vol. 5, 1974.
- ERTHAL, Guaraci J.; NETO, Gilberto C. e ALVES, Diógenes S. A General Data for Geographic Information Systems. *Proceedings of the 16th Congress of International Society for Photogrammetrie and Remote Sensing*. Kyoto, 1988. 10p.
- EYRE, A.L.; ADOLPHUS, B. e AMIEL, M. Census Analysis and Population Studies. *Photogrammetric Engineering*. v.36, n. 5. 1970. p.460-466.
- EYTON, J. Ronald. SPOT PLA Photographic Image Processing. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 8, agosto 1990. p. 1129-1134.
- FAUST, Nickolas L. Automated Data Capture for Geographic Information Systems: A Commentary. *Photogrammetric Engineering & Remote Sensing*. v. 53, n. 10, outubro 1987. p. 1389-1390.
- FEIGENBAUM, E. *The Rise of the Expert Company*. Times Books, New York. 1988.

- FERRARI, Célson. *Curso de Planejamento Municipal Integrado: Urbanismo*. 6. ed. São Paulo, Pioneira, 1988. 632p.
- FIGUEIRA, Eduardo L. C.; ROCHA, Wellington C. da; ROCHA, Helio O.; CLEMENTE, Dimas; SCHMIDIN, Dirley; MOTTER, Irineu e VASCONCELOS, Elinaldo de E. Utilização de imagens TM-LANDSAT-5 no Mapeamento Temático da Faixa de Estudo para Implantação do Gasoduto Bolívia-Brasil. *Anais do XVI Congresso Brasileiro de Cartografia*. Rio de Janeiro, 04-08 outubro 1993. v.1. p. 112-115.
- FISCHER, Mônica Veríssimo; SOARES, Laura R. S. de B.; FRANZ, Litz M. B e NASCIMENTO, Iuli. Utilização de Imagens TM/LANDSAT na Análise da Dinâmica de Ocupação do Solo do Distrito Federal - Inventário. *Anais do II Encontro Nacional de Sensoriamento Remoto Aplicado ao Planejamento Municipal*. Serra Negra, 2-5 abril 1991. p. 129-133.
- FISCHLER, Martin A. e FIRSCHEIN, Oscar. *Intelligence: The Eye, the Brain, and the Computer*. Reading, Addison- Wesley, 1987. 332p.
- FISHER, Peter F. e LINDENBERG, Richard E. On Distinctions Among Cartography, Remote Sensing, and Geographic Information Systems. *Photogrammetric Engineering & Remote Sensing*. v. 55, n. 10, outubro 1989. p. 1431-1434.
- FONSECA, Leila M. G.; BINS, Leonardo S.; VELASCO, Flávio R. Dias e MONTEIRO, A, M. V. Sistema de Segmentação Baseado em Conhecimento para Imagens de Satélite. *Anais do VI Simpósio Brasileiro de Sensoriamento Remoto*. Manaus, 24-29 junho 1990. v. 1. p. 197-200.
- FOODY, G.M.; CAMPBELL, N.A.; TRODD, N.M. e WOOD, T.F. Derivation and Applications of Probabilistic Measures of Class Membership from the Maximum-Likelihood Classification. *Photogrammetric Engineering & Remote Sensing*. v. 58, n. 9, setembro 1992. p. 1335-1341.
- FORESTI, Celina. Técnicas de Sensoriamento Remoto Aplicadas ao Estudo de Regiões Metropolitanas - o Setor Oeste da Área Metropolitana de São Paulo. *Anais do Encontro Nacional de Sensoriamento Remoto Aplicado ao Planejamento Municipal*. Campos de Jordão, 22-23 outubro 1987. p. 020-031.
- FORESTI, Celina. Impacto Ambiental da Expansão Urbana no Setor Oeste da Área Metropolitana de São Paulo: Análise através de Dados e Técnicas de Sensoriamento Remoto. *Anais do V Simpósio Brasileiro de Sensoriamento Remoto*. Natal, 11-15 outubro 1988. v.1. p. 124-130.
- FORESTI, C.; FLORENZANO, T.G.; ERTHAL, G.J. e GODOY JR., M. Integração de Dados do Satélite SPOT com um Modelo Digital de Terreno para Avaliação de Impacto Ambiental. *Anais do XIV Congresso Brasileiro de Cartografia*. Gramado, 21-26 maio 1989. p. 686-689.

- FORSTER, Bruce. Some Urban Measurements from Landsat Data. *Photogrammetric Engineering & Remote Sensing*. v. 49, n. 12, dezembro 1983. p. 1693-1707.
- FRANK, Andrew U. Requirements for a Database Management System for a GIS. *Photogrammetric Engineering & Remote Sensing*. v. 54, n. 11, novembro 1988. p. 1557-1564.
- FRANKLIN, Steven E. e WILSON, Bradley A. A Three-Stage Classifier for Remote Sensing of Mountain Environments. *Photogrammetric Engineering & Remote Sensing*. v. 58, n.4, abril 1992. p. 449-454.
- FRANKOT, Robert T. e CHELLAPA, Rama. Estimation of Surface Topography From SAR Imagery Using Shape From Shading Techniques. *Artificial Intelligence*. v. 43, n. 3, junho 1990. p. 271-310.
- FRANZONI, Ana Maria Benciveni. *Aplicação do Sensoriamento Remoto no Monitoramento de Áreas Sujeitas à Degradação Ambiental: O Caso da Bacia Hidrográfica do Sangão - SC*. Dissertação de Mestrado. Curso de Pós-Graduação em Geografia. Universidade Federal de Santa Catarina, Florianópolis, SC. 1993. 148 p.
- FRANZONI, Ana Maria Benciveni; ALVES, Alceu Ribeiro; LAPOLLI, Flávio Rubens e BASTOS, Lia Caetano. Utilização do Classificador Distância Euclidiana: Bacia Hidrográfica do Sangão. *Anais do XVI Congresso Brasileiro de Cartografia*. Rio de Janeiro; 04-08 outubro 1993. v. 1. p. 101-106.
- FROST, Richard. *Introduction to Knowledge Based Systems*. New York, Macmillan Publishing Company, 1986. 677p.
- FRYBENBERG, Mrck e GALLANT, Stephen I. Fuzziness and Expert System Generation. *Proceedings of the International Conference on Information Processing and Management of Uncertainty in Knowledge-Based System*. Paris, 1986. p. 137-141.
- FU, King Sun. *Syntactic Pattern Recognition and Applications*. Englewood Cliffs, Prentice-Hall, 1982, 593p.
- FUNG, Tung e LEDREW, Ellsworth. The Determination of Optimal Threshold Levels for Change Detection Using Various Accuracy Indices. *Photogrammetric Engineering & Remote Sensing*. v. 54, n. 10, outubro 1988. p. 1449-1454.
- GAINES, Brian R. e SHAW, Mildred L. G. From Fuzzy Logic to Expert Systems. *Information Sciences*. v. 36, 1985. p. 5-16.
- GESÙ, V. Di e MACCARONE, M. C. Features Selection and Possibility Theory. *Pattern Recognition*. v. 19, n. 1. 1986. p. 63-72.

- GIORDANA, A. e SAITTA L. An Expert System Oriented to Complex Pattern Recognition Problems. *Information Sciences*. v. 36, 1985. p. 157-177.
- GOLDBERG, M.; KARAM, G. e ALVO, M. A Production Rule-Based Expert System for Interpreting Multitemporal LANDSAT Imagery. *Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Washington, 1983. p77-82.
- GOLDSZEIN, Mário e CARNOTA, Raul. *Inteligencia Artificial Aplicada - Lógica y Representación del Conocimiento*. Campinas, Editora da UNICAMP, 1986. 100p.
- GONG, Peng e HOWARTH, Philip J. Frequency-Based Contextual Classification and Gray-Level Vector Reduction for Land-Use Identification. *Photogrammetric Engineering & Remote Sensing*. v. 58, n. 4, abril 1992. p. 423-437.
- GOODENOUGH, D.; GOLDBERG, M.; PLUNKETT, G. e ZELEK, J. An Expert System for Remote Sensing. *IEEE Transactions on Geoscience and Remote Sensing*. GE-25. 1987. p.349-359.
- GOSHTASBY, Ardeshir, e STOCKMAN, George C. Point Pattern Matching Using Convex Hull Edges. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 15, n. 5, setembro-outubro 1985. p. 631-637.
- GREEN, W.B. Quantitative Image Processing Techniques. *Digital Image Processing*. New York, Van Nostrand Reinhold, 1983. p. 77-105.
- GROSSER, Konrad. Measurement of Deforested Areas by Image Processing Technique - A Methodological Study. *Anais do VI Simpósio Brasileiro de Sensoriamento Remoto*. Manaus, 24-29 junho 1990. v. 1. p. 24-27.
- GUERRA, Francisco e RUIZ, Gustavo. Levantamento de la Cobertura en Areas Montañosas Tropicales, Mediante la Aplicación de Técnicas Visuales y Digitales en Imágenes de Satelite. *Anais do VI Simpósio Brasileiro de Sensoriamento Remoto*. Manaus, 24-29 junho 1990. v. 1. p. 220-226.
- GUPTA, M. M. On the Cognitive Computing: Perspectives. *Fuzzy Logic in Knowledge-Based Systems, Decision and Control*. Editado por M.M. Gupta e T. Yamakawa.1991. p. 7-10.
- GURNEY, Charlotte M. e TOWNSHEND, John R. G. The Use of Contextual Information in the Classification of Remotely Sensed Data. *Photogrammetric Engineering & Remote Sensing*. v. 49, n. 1, janeiro 1983. p. 55-64.
- HAACK, B.N. Mutisensor Data Analysis of Urban Environments. *Photogrammetric Engineering & Remote Sensing*. v. 50, n. 10, outubro 1984. p. 1471-1477.

- HABIAGA, Lydia A. G. de P.; MADUREIRA, Marta S. P. e ASMUS, Haroldo E. Uso de Imagens de Satélite Aplicadas ao Estudo de Áreas Urbanas nas Cidades de Rio Grande, Pelotas e São José do Norte, Rio Grande do Sul. *Anais do II Encontro Nacional de Sensoriamento Remoto Aplicado ao Planejamento Municipal*. Serra Negra, 2-5 abril 1991. p. 141-148.
- HABIAGA, Lydia A. G. de P.; MADUREIRA, Marta S. P. e SALVATORI, E. Evolução Urbana das Cidades que Margeiam a Lagoa dos Patos, R.S. *Anais do II Encontro Nacional de Sensoriamento Remoto Aplicado ao Planejamento Municipal*. Serra Negra, 2-5 abril 1991. p. 149-155.
- HADAD, Renato Moreira e VELASCO, Flávio R. Dias. Um Sistema de Processamento de Imagens de Satélite de Baixo Custo que Auxilia na Tarefa de Interpretação. *Anais do VI Simpósio Brasileiro de Sensoriamento Remoto*. Manaus, 24-29 junho 1990. v. 1. p. 142-145.
- HADIPRIONO, Fabian C.; LYON, Jonh G.; LI, Thomas e ARGIALAS, Demetre P. The Development of a Knowledge-Based Expert System for Analysis of Drainage Patterns. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 6, junho 1990. p. 905-909.
- HALL, Lawrence O.; SZABO, Sue e KANDEL, Abraham. On the Derivation of Memberships for Fuzzy Sets in Expert Systems. *Information Sciences*. v. 40, 1986. p. 39-52.
- HALLIDAY, Daniel L.; MCGILLEM, Clare; WESTERKAMP, Jonh e AUNON, Jorge I. Optimal and Suboptimal Feature Selection for Classification of Evoked Brain Potentials. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 15, n. 3, maio-junho 1985. p. 442-448.
- HAMBURGER, Diana Sarita e FORESTI, Celina. The Use of Information Supplied by Textural Characteristics of Orbital Images in the Determination of Urban Land Use Classes. *Proceedings of the Twenty-Fourth International Symposium on Remote Sensing of Environment*. Rio de Janeiro, 27-31 maio 1991. v. 2. p. 665-670.
- HARALICK, R.M. Glossary and Index to Remotely Sensed Image Pattern Recognition Concepts. *Pattern Recognition*. v. 5, 1973. p.391-403.
- HARALICK, Roberto M.; SHANMUGAM, K. e DINSTEN, Its'Hak. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*. v.SMC-3, N.6, novembro 1973. p. 610-621.
- HARRINGTON, John A. Jr.; CARTIN, Kevin F. e LOUGEAY, Ray. The Digital Image Analysis System (DIAS): Microcomputer Software for Remote Sensing Education. *Photogrammetric Engineering & Remote Sensing*. v. 52, n. 4, abril 1986. p. 545-550.

- HARRIS, J.R.; MURRAY, R e HIROSE, T. IHS Transform for the Integration of Radar Imagery with other Remotely Sensed Data. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 12, dezembro 1990. p. 1631-1641.
- HARTIGAN, John A. *Clustering Algorithms*. New York, John Wiley, 1975. 352p.
- HELDER, Dennis L.; QUIRK, Bruce K. e HOOD, Joy. A Technique for the Reduction of Banding in Landsat Thematic Mapper Images. *Photogrammetric Engineering & Remote Sensing*. v. 58, n.10, outubro 1992. p.1425-1431.
- HEPNER, G.F., LOGAN, T. e RITTER, N. Artificial Neural Network Classification Using a Minimal Training Set: Comparison to Conventional Supervised Classification. *Photogrammetric Engineering & Remote Sensing*. v 56, n. 4, abril 1990. p. 469-473.
- HODGSON, Michael E. e PLEWS, Reese W. N-Dimensional Display of Cluster Means in Feature Space. *Photogrammetric Engineering & Remote Sensing*. v. 55, n. 5, maio 1989. p. 613-619.
- HOOD, Joy; LADNER, Lyman e CHAMPION, Richard. Image Processing Techniques for Digital Orthophotoquad Production. *Photogrammetric Engineering & Remote Sensing*. v. 55, n, 9, setembro 1989. p. 1323-1329.
- HUANG, Scott L. Applications of Digital Image Processing to Photoelastic Stress Analysis. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 4, abril 1990. p. 495-499.
- HUMPHREYS, Rubens Dias. Aplicação de Estatística Multivariada no Processamento Digital de Imagens. *Anais do VI Simpósio Brasileiro de Sensoriamento Remoto*. Manaus, 24-29 junho 1990. v. 1. p. 135-141.
- HUTCHINSON, Charles F. Techniques for Combining Landsat and Ancillary Data for Digital Classification Improvement. *Photogrammetric Engineering & Remote Sensing*. v. 48, n. 1, janeiro 1982, p.123-130.
- IBBS, William C. Future Directions for Computerized Construction Research. *Journal of Construction Engineering*. V. 112, n. 3, setembro. 1986. p.326-345.
- ICHINO, Manabu e SKLANKY, Jack. Optimum Feature Selection by Zero-One Integer Programming. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 14, n. 5, setembro-outubro 1984. p. 737-746.
- IRVIN, R. Bruce E MCKEOWN, David M. Jr. Methods for Exploiting the Relationship Between Buildings and Their Shadows in Aerial Imagery. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 19, n. 6, novembro-dezembro 1989. p. 1564-1575.

- JACOBS, G.A.; MAXIMIANO, G.A. e IHLENFELD, R.G.K. Identificação do Uso Atual do Solo através de Imagens de Satélite para Subsidiar Ações de Âmbito Fundiário do Paraná. *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. I. p. 068-074.
- JAKUBOWSKI, Ryszard. A Structural Representation of Shape and Its Features. *Information Sciences*. v. 39, 1986. p. 129-151.
- JAKUBOWSKI, Ryszard. Decomposition of Complex Shapes for their Structural Recognition. *Information Sciences*. v. 50, n. 1, fevereiro 1990. p. 35-71.
- JENSEN, John R. *Introductory Digital Image Processing - A Remote Sensing Perspective*. Englewood Cliffs, Prentice-Hall, 1986. 379 p.
- JOHNSON, R. e WICHERN, D. *Applied Multivariate Statistical Analysis*. 2.ed. Englewood Cliffs, Prentice Hall, 1988. 607 p.
- JOHNSTON, Kevin M. Natural Resource Modeling in the Geographic Information System Environment. *Photogrammetric Engineering & Remote Sensing*. v. 53, n. 10, outubro 1987. p. 1411-1415.
- JORIA, Peter E.; AHEARN, Sean C. e CONNOR, Michael. A Comparison of the SPOT and LANDSAT Thematic Mapper Satellite Systems for Detecting Gypsy Moth Defoliation in Michigan. *Photogrammetric Engineering & Remote Sensing*. v. 57, n.12, dezembro 1991, p.1605-1612.
- KACPRZYK, Janus e YAGER, Ronald R. Emergency-Oriented Expert Systems: a Fuzzy Approach. *Information Sciences*. v. 37, 1985. p. 143-155.
- KANDEL, A. *Fuzzy Mathematical Techniques With Applications*. Reading, Addison-Wesley, 1986.
- KANDEL, A. *Fuzzy Techniques in Pattern Recognition*. New York, John Wiley, 1982.
- KAPUR, J. N. Application of Entropic Measures of Stochastic Dependence in Pattern Recognition. *Pattern Recognition*. v. 19, n. 6, 1986. p. 473-476.
- KEATING, Terrence; PHILLIPS, William e INGRAM, Kevin. An Integrated Topologic Database Design for Geographic Information Systems. *Photogrammetric Engineering & Remote Sensing*. v. 53, n. 10, outubro 1987. p. 1399-1402.
- KENDALL, M.G e STUART, A. *The Advanced Theory of Statistics*. 2.ed. Londres, Charles Griffin, 1967. 690 p.
- KELLER, James M. e QIU, Hongjie. Fuzzy Sets Methods in Pattern Recognition. *Proceedings of the 4th International Conference on Pattern Recognition*, Cambridge, 1988. p. 173-182.

- KELLER, James M.; GRAY, Michael R. e GIVENS Jr., James A. A Fuzzy K-Nearest Neighbor Algorithm. *IEEE Transactions on Systems, Man, and Cybernetics*. v. SMC-15, n. 4, julho-agosto 1985. p. 580-585.
- KELLER, Robert. *Expert System Technology. Development and Application*. Englewood Cliffs, Yordon Press, 1987. 246p.
- KHANNA, T. *Foundations of Neural Networks*. Reaging, Addison-Wesley, 1990. 196 p.
- KLEIN, Ruben e PRESS, S. James Contextual Bayesian Classification of Remotely Sensed Data When Training Data is Part of the Scene. *Revista Brasileira de Probabilidade e Estatística*. v. 4, n. 1, maio 1990, p. 43-67.
- KOVALICK, William M. e NEWCOMER, Jeffrey A. A Methodology for Evaluation of an Interactive Multispectral Image Processing System. *Photogrammetric Engineering & Remote Sensing*. v. 53, n. 8, agosto 1987. p. 1087-1092.
- KROGULECKI, Mathew. A Prototype Decision Guide and Audit Log for Preparation of Spatial Databases. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 4, abril 1990. p. 505-509.
- KURKDJIAN, Maria de Lourdes N. de O. Integração de Dados de Diferentes Sistemas Sensores através da Técnica de Transformação IHS, visando o Estudo da Estrutura Intra-Urbana. *Anais do VI Simpósio Brasileiro de Sensoriamento Remoto*. Manaus, 24-29 junho 1990. v. 2. p. 331-335.
- LABOVITZ, M. L. Issues Arising from Sampling Designs and Band Selection in Discriminating Ground Reference Attributes Using Remotely Sensed Data. *Photogrammetric Engineering & Remote Sensing*. v. 52, n. 2, fevereiro 1986. p. 201-211.
- LAPOLLI, Édis; ALVES, Alceu Ribeiro; LOCH, Carlos; BARCIA, Ricardo Miranda. Representação de Informações Difusas na Classificação de Imagens Digitais, Visando à Elaboração de Mapas Temáticos. *Anais do XV Congresso Brasileiro de Cartografia*. São Paulo, 28 julho - 2 agosto 1991. v.3. p. 433-437.
- LAPOLLI, Édis Mafra; ALVES, Alceu Ribeiro; BASTOS, Lia Caetano e LAPOLLI, Flávio Rubens. Clasificación de Imágenes Digitales: Técnicas Usuales y Nuevas Perspectivas. *Memórias del 5to Simposio Latinoamericano de Percepción Remota*. Cuzco, Peru, 28 outubro - 01 novembro 1991. p. 589-595.
- LAPOLLI, Édis Mafra; ALVES, Alceu Ribeiro e BARCIA, Ricardo Miranda. Classificação de Imagens Digitais: Comparação entre Vários Métodos. *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. II, p. 373-380.

- LAPOLLI, Édis Mafra; ALVES, Alceu Ribeiro; LUZ, Victor José Philippi e ZARDO, Soraia Marinon. Utilização de Filtros para o Realce de Áreas Urbanas. *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. 1, p.75-82.
- LEARY, M. E. Knowledge and Reasoning in Development Control and Urban Design: an Expert Systems Approach. *Environment, Planning and Design*. v. 15, 1988. p. 383-398.
- LEE, David Chung Liang; SHIMABUKURO, Yosio Edemir & HERNANDEZ FILHO, Pedro. Análise de Componentes Principais para o Monitoramento de Áreas Reflorestadas. *Anais do VI Simpósio Brasileiro de Sensoriamento Remoto*. Manaus, 24-29 junho 1990. p. 48-60.
- LI, Zi Cai; GU, Quan Lin; SUEN, Ching Y e BUI, Tien Dai. A Comparative Study of Nonlinear Shape Models for Digital Image Processing and Pattern Recognition. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 20, n. 4, julho-agosto 1990. p. 858-871.
- LI, Hua e YANG, Hiun S. Fast and Reliable Image Enhancement Using Fuzzy Relaxation Technique. *IEEE Transactions on Systems, Man and Cybernetics*. v. 19, n. 5, setembro-outubro 1989. p. 1276-1281.
- LIMA, W. C. e BARRETO, J. M. Inteligência Artificial. *Ciência Hoje*. v. 7, n. 38, dezembro 1987. p. 50-56.
- LIN, Wei-Chung e FU, King-Sun. A Syntactic Approach to Three-Dimensional Object Recognition. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 16, n. 3, maio-junho 1986. p. 405-422.
- LIPARI, Charles; TRIVEDI, Mohan e HARLOW, Charles. Geometric Modeling & Recognition of Elongated Regions in Aerial Images. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 19, n. 6, novembro-dezembro 1989. p. 1600-1612.
- LIU, C. Richard e SRINIVASAN, Ramesh. Generative Process Planning Using Syntactic Pattern Recognition. *Computers in Mechanical Engineering*. março 1984. p. 63-66.
- LIU, Z. Q e CAELLI, Terry M. Multiobject Pattern Recognition and Detection in Noisy Backgrounds Using a Hierarchical Approach. *Computer, Graphics, and Image Processing*. v. 44, n. 3, dezembro 1988. p. 296-306.
- LOGAN, Thomas L. e BRYANT, Nevin A. Spatial Data Software Integration: Merging CAD/CAM/MAPPING with GIS and Image Processing. *Photogrammetric Engineering & Remote Sensing*. v. 53, n. 10, outubro 1987. p. 1391-1395.

- LOWELL, Kim E. A Probabilistic Modification of the Decision Rule in the Skidmore Supervised Nonparametric Classifier. *Photogrammetric Engineering & Remote Sensing*. v. 55, n. 6, junho 1989, p. 897-900.
- MAJUMDER, D. Dutta. A Unified Approach to Artificial Intelligence, Pattern Recognition, Image Processing, and Computer Vision in Fifth-Generation Computer Systems. *Information Sciences*. v. 45, 1988. p. 391-431.
- MARBLE, Duane F. The North American Geoprocessing Experience: Lessons and Future Prospects. *Anais do Simpósio Brasileiro de Geoprocessamento*. São Paulo, 23-25 maio 1990. p. 66-78.
- MARTINS, M.R.; MATTOS, J.T. e BRANDINI, F.P. Técnicas de Realce Orbitais Evidenciando as Variações Espectrais da Massa de Água Superficial das Baías de Paranaguá e Antonina - PR. *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. IV. p. 181-189.
- MARTINS, Mauro Ribeiro; LUZ, Victor José Philippi e SOARES, Carlos Roberto. Estudo das Variações Espaciais e Temporais da Linha de Costa e da Formação de Bancos de Areia entre Pontal do Sul e Ilha da Galheta, Paranaguá-PR, por meio de Imagens Orbitais. *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. IV, p.170-180.
- MASCARENHAS, Nelson D. A. e VELASCO, Flávio R. D. *Processamento Digital de Imagens*. 2 ed. Buenos Aires, KAPELUSZ, 1989. 384p.
- MASELLI, Fabio; CONESE, Claudio; PETKOV, Ljiljana e RESTI, Raffaello. Inclusion of Prior Probabilities Derived from a Nonparametric Process into the Maximum-Likelihood Classifier. *Photogrammetric Engineering & Remote Sensing*. v. 58, n. 2, fevereiro 1992. p. 201-207.
- MATSUYAMA, Takashi. Expert Systems for Image Processing: Knowledge-Based Composition of Image Analysis Processes. *Computer Vision, Graphics, and Image Processing*. v. 48, 1989. p. 22-49.
- MAUSEL, P. W.; KRAMBER, W. J. e LEE, J. K. Optimum Band Selection for Supervised Classification of Multispectral Data. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 1, janeiro 1990. p. 55-60.
- MAZZOCATO, M.E.; TORRUSIO, S. e MAKOWIECKI, C.L. Integración de Metodología Visual y Digital de Imágenes Satelitarias en el Sector Sudoeste de la Provincia de Buenos Aires, (Argentina). *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. I. p. 104-111.
- McCAFFERTY, J. D. e FRYER, R. J. Flexible Feature Detector for Binary Video Images. *IEE Proceedings-E*. v. 134, n. 5, setembro 1987. p. 243-246.

- McGWIRE, Kenneth C. Analyst Variability in Labeling of Unsupervised Classifications. *Photogrammetric Engineering & Remote Sensing*. v. 58, n. 12, dezembro 1992. p. 1673-1677.
- McKEOWN, D.; HARVEY, W. e McDERMOTT, J. Rule-Based Interpretation of Aerial Imagery. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. PAMI-7, n. 5.1985.p.570-585.
- McKEOWN, David M. Jr; HARVEY, Wilson A e WIXSON, Lambert E. Automating Knowledge Acquisition for Aerial Image Interpretation. *Computer Vision, Graphics, and Image Processing*. v. 46, n. 1, abril 1989. p. 37-81.
- MEDEIROS, José S. de e AMARO, E. da Silva. Mapeamento das Alterações da Cobertura Vegetal Natural: Novo Procedimento Metodológico Utilizando-se os Sistemas SITIM/SGI. *Anais do VI Simpósio Brasileiro de Sensoriamento Remoto*. Manaus, 24-29 junho 1990. v. 1. p. 91-96.
- MEHLDAU, Gerhard e SCHOWENGERDT, Robert A. A C-Extension for Rule-Based Image Classification Systems. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 6, junho 1990. p. 887-892.
- MENDES, Celso Luiz. Classificação por Máxima Verossimilhança num Ambiente Maciçamente Paralelo. *Anais do V Simpósio Brasileiro de Sensoriamento Remoto*. Natal, 11-15 outubro 1988. v. 2, p. 491-496.
- MICHALEK, Jeffrey L.; WAGNER, Thomas W.; LUCZKOVICH, Joseph J. e STOFFLE, Richard W. Multispectral Change Vector Analysis for Monitoring Coastal Marine Environments. *Photogrammetric Engineering & Remote Sensing*. v. 59, n. 3, março 1993, p.381-384.
- MICHEL, A. e DUREAU, F. Teledetección Aerea y Espacial en Medio Urbano y Observación Demográfica. Avance de la Investigación a través de la Literatura Francesa e Inglesa. *Revista SELPER*. v. 6, n. 4, dezembro 1990. p.36-47.
- MOLLER-JENSEN, Lasse. Knowledge-Based Classification of Urban Area Using Texture and Context Information in Landsat-TM Imagery. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 6, junho 1990. p. 899-904.
- MONTEIRO, Antonio M. Vieira e VELASCO, Flávio R. Dias. Satellite Image Using Low Level Symbolic Structures. *Proceedings of the 16th Congress of International Society for Photogrammetry and Remote Sensing*. Kyoto, 1988. 8p.
- MORANDI, C.; PIAZZA, F. e CAPANCIONI, R. Digital Image Registration by Phase Correlation Between Boundary Maps. *IEEE Proceeding-E*,.v. 134, n. 2, março 1987.

- MOREIRA, Maurício Alves. Avaliação de Resultados de Classificação Digital de Cultura de Verão numa Área Teste do Estado do Paraná - Ano Safra 1986/87. *Anais do V Simpósio Brasileiro de Sensoriamento Remoto*. Natal, 11-15 outubro 1988. v. 1. p. 180-185.
- MOSSE, Daniel. Pattern Matching Techniques. *Revista de Informática Teórica e Aplicada*. v.1, n. 2, maio 1990. p. 9-35.
- MURTHY, S. Vasudev. Fuzzy Sets and Typicality Theory. *Information Sciences*. v. 51, n. 1, junho 1990. p. 61-93.
- NAZIF, Ahmed M. e LEVINE, Martin D. Low Level Image Segmentation: an Expert System. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. v. 6, n. 5, setembro 1984. p. 555-577.
- NELSON, M.M. e ILLINGWORTH, W.T. *A Practical Guide to Neural Nets*. Reading, Addison-Wesley, 1990. 344 p.
- NOVO, Evelyn M. L. de Moraes. *Sensoriamento Remoto. Princípios e Aplicações*. Sao Paulo, Edgar Blücher, 1989. 307 p.
- OGROSKY, C.E. Population Estimates from Satellite Imagery. *Photogrammetric Engineering & Remote Sensing*. v.41. 1975. p. 707-712.
- OLIVEIRA, Celso N. E. de . Sistema de Informação Geográfica em Computadores de Pequeno Porte: Aplicações em Planejamento Ambiental. *Anais do VI Simpósio Brasileiro de Sensoriamento Remoto*. Manaus, 24-29 junho 1990. v. 3. p. 753-762.
- ONISAWA, Takehisa. A Representation of Human Reliability Using Fuzzy Concepts. *Information Sciences*. v. 45, 1988. p. 153-173.
- ORTOLANO, L. e PERMAN, C. D. *System Expert: Applications to Urban Planning*. Springer - Verlag, 1990. Capítulo 2. 268p.
- ORTOLANO, Leonard e PERMAN, Catherine D. Software for expert Systems Development. *Journal of Computing in Civil Engineering*. v.1, n. 4, outubro 1987, p.225-240.
- OWEN, T. *Expert Systems: The Key Facts for Decision Makers*, Cranfield, Cranfield Press. 1987.
- PAL, Sankar K. e GHOSH, Ashish. Image Segmentation Using Fuzzy Correlation. *Information Sciences*. v. 62, 1992. p.223-250.
- PAO, Yoh-Han. *Adaptative Pattern Recognition and Neural Networks*. Reading, Addison-Wesley, 1989. 310 p.

- PARKS, Nancy F. e PETERSEN, Gary W. High Resolution Remote Sensing of Spatially and Spectrally Complex Coal Surface Mines of Central Pennsylvania: A Comparison Between Simulated SPOT MSS and Landsat-5 Thematic Mapper. *Photogrammetric Engineering & Remote Sensing*. v. 53, n. 4, abril 1987. p. 415-420.
- PATRICK, Edward A. e FATTU, James M. *Artificial Intelligence With Statistical Pattern Recognition*. Englewood Cliffs, Prentice Hall, 1986. 372p.
- PEREIRA, Madalena Niero; KURKDJIAN, Maria de Lourdes N. de O. e SAMPAIO, Bernardo de Oliveira. Mapeamento do Uso da Terra do Município de São José dos Campos por Sensoriamento Remoto, como Subsídio para a Elaboração de seu P.D.D.I. *Anais do Encontro Nacional de Sensoriamento Remoto Aplicado ao Planejamento Municipal*. Campos do Jordão, 22-23 outubro 1987. p. 001-019.
- PEZZI, Luciano Ponzi e PROVITINA, Flávio. Definição e Comparação de Coordenadas Geográficas em Imagem e Mapa para o Rio Madeira em Porto Velho. *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. IV. p.371-380.
- PIWOWAR, Joseph M. e LEDREW, Ellsweth F. Integrating Spatial Data: A User's Perspective. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 11, novembro 1990, p. 1497-1502.
- POMPÉIA, Sérgio Luis e FORESTI, Celina. O Impacto da Ocupação Desordenada em Sub-bacias Urbanas: Sub-bacia do Rio Cabuçu - Região Metropolitana de São paulo (SP). *Anais do Encontro Nacional de Sensoriamento Remoto Aplicado ao Planejamento Municipal*. Campos do Jordão, 22-23 outubro 1987. p. 069-079.
- POROS, Demetrios J. e PETERSON, Chris J. Methods for Destriping Landsat Thematic Mapper Images - A Feasibility Study for an Online Destriping Process in the Thematic Mapper Image Processing System (TIPS). *Photogrammetric Engineering & Remote Sensing*. v. 51, n. 9, setembro 1985. p. 1371-1378.
- PUTTE, Robert Van de. Farming Systems and Land Use Modelling for Watershed Management. *ITC Journal*. v. 1, 1988. p. 83-86.
- QUINTANILHA, José Alberto. Processamento de Imagens Digitais. *Anais do Simpósio Brasileiro de Geoprocessamento*. São Paulo, 23-25 maio 1990. p. 37-52.
- RALESCU, Anca L. A Note on Rule Representation in Expert Systems. *Information Sciences*. 1986. p. 193-203.
- RAMASWAMY, R.; MORRIS, D. T. e ASPINALL, Prof. D. Detecting Edges in an Image Using Powers-of-Two Coefficients. *IEE Proceedings-E*. v. 137, n. 3, maio 1990.

- RASSON, J.P.; ORBAN-FERAUGE, F. e GRANVILLE, V. About Estimates of Measures of the Convex Hulls of Sets of Points Related to the Problem of Supervised Classification. *Proceedings of the Twenty-Fourth International Symposium on Remote Sensing of Environment*. Rio de Janeiro, 27-31 maio 1991. v. 2. p. 883-891.
- REEVES, Colin V.; ZEIL, Peter W. e YUNXUAN, Zhou. Interpretation of Airbone Geophysical Surveys: Some Potential Applications of Image Processing Techniques and Geographic Information Systems in Systematic Exploration Strategy. *ITC Journal*, n. 2, 1990, p. 126-136.
- RIBEIRO, Carlos A. A. Soares; RIBEIRO, José Carlos e BRITES, Ricardo Seixas. Gavião - An Alternative System for Image Processing. *Anais do VI Simpósio Brasileiro de Sensoriamento Remoto*. Manaus, 24-29 junho 1990. v. 1. p. 163-166.
- RIBEIRO, Horácio da Cunha e Souza. *Introdução aos Sistemas Especialistas*. Rio de Janeiro, Livros Técnicos e Científicos, 1987. 142p.
- RICH, Elaine. *Artificial Intelligence*. New York, Macgraw-Hill, 1983, 436 p.
- RICHARDS, John A. *Remote Sensing Digital Image Analysis*. Londres, Springer-Verlag, 1986. 281 p.
- RICHARDSON, Dianne E. Database Desing Considerations for Rule-Based Map Feature Selection. *ITC Journal*. n. 2, 1988. p. 165-171.
- RIPPLE, William J. e ULSHOEFER, Veit S. Expert Systems and Spatial Data Models for Efficient Geographic Data Handling. *Photogrammetric Engineering & Remote Sensing*. v. 53, n. 10, outubro 1987. p. 1431-1433..
- RITTER, Paul. A Vector-Based Slope and Aspect Generation Algorithm. *Photogrammetric Engineering & Remote Sensing*. v. 53, n. 8, agosto 1987. p. 1109-1111.
- ROBINSON, V. B.; FRANK, A. U. e BLAZE, M. A. Expert Systems and Geographic Information Systems: Review and Prospects. *Expert Systems in Engineering*. 1988. p. 203-214.
- ROBINSON, Vicent B. Expert Systems for Geographic Information Systems. *Photogrammetric Engineering & Remote Sensing*. v. 53, n. 10, outubro 1987. p. 1435-1441.
- ROSENFELD, Azriel. Pyramid Algorithms for Finding Global Structures in Images. *Information Sciences*. v. 50, n. 1, fevereiro 1990. p. 23-34.
- ROSS, Timothy D. e LAIR, Alan V. On the Role of Pattern in Recognizer Design. *Proceedings of the 4th International Conference on Pattern Recognition*. Cambridge, 1988. p. 193-202.

- RYRSON, Robert. Image Interpretation Concerns for the 1990s and Lessons from the Past. *Photogrammetric Engineering & Remote Sensing*. v. 55, n. 10, outubro 1989. p. 1427-1430.
- SAATY, Thomas L. Scaling the Membership Function. *European Journal of Operation Research*. n. 25, 1986. p. 320-329.
- SCHENK, Tony e ZILBERSTEIN, Ofer. Experiments With a Rule-Based System for Interpreting Linear Map Features. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 6, junho 1990. p. 911-917.
- SCHLÜNZEN, Elisa Tomoe Moriya; TRINDADE, Maria de Lourdes Bueno; SHIMABUKURO, Milton Hirokazu; SCHLÜNZEN JÚNIOR, Klaus e ANDRADE NETO, Márcio Luís. *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. II. p. 438-444.
- SCHOWENGERDT, Robert A. e WANG, Han-Lung. A General Purpose Expert System for Image Processing. *Photogrammetric Engineering & Remote Sensing*. v. 55, n. 9, setembro 1989. p. 1277-1284.
- SENNE, Edson L. F. Motor de Inferência para Sistemas Especialistas. *Proceedings of the Eighth SCCC International Conference on Computer Science*. Santiago, 1988, v. 2. p. 1-9.
- SENNE, Edson L. F.; MONTEIRO, Antonio M, V.; BINS, Leonardo S., JUNIOR, A. Francisco e VELASCO, Flávio R. Dias. Um Sistema Especialista para Especificação de Produtos de Imagem de Satélite. *Anais do V Simpósio Brasileiro de Sensoriamento Remoto*. Natal, 11-15 outubro 1988. p. 505-512.
- SHEFFIELD, Charles. Selection Band Combinations from Multispectral Data. *Photogrammetric Engineering & Remote Sensing*. v. 51, n. 6, junho 1985. p. 681-687.
- SHETTIGARA, Vittala K. A Generalized Component Substitution Technique for Spatial Enhancement of Multispectral Images Using a Higher Resolution Data Set. *Photogrammetric Engineering & Remote Sensing*. v. 58, n. 5, maio 1992. p. 561-567.
- SILVA, Antonio da. Comparação entre Dois Métodos de Fusão de Imagens de dados LANDSAT TM e SPOT Pancromático. *Anais do XVI Congresso Brasileiro de Cartografia*. Rio de Janeiro, 04-08 outubro 1993. v.1. p. 116-122.
- SILVA, Antonio José Ferreira Machado e. Classificação Paramétrica Não-Supervisionada por Máxima Probabilidade a Posteriori. *Anais do VII Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. II, p. 453-457.
- SILVA, Antonio José Ferreira Machado e. Métodos de Avaliação de Modelos de Classificação de Imagens Digitais. *Anais do Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba, 10-14 maio 1993. v. II, p. 445-452.

- SILVA, Barbara-Christine Nentwig. A organização Espacial do Estado da Bahia através do Modelo Potencial. *Revista Brasileira de Geografia*. v. 52, n. 2, abril-junho, 1990. p. 83-88.
- SILVA, Sylvio Bandeira de Mello e SOUZA, Jaimeval Caetano de. Uma Medida da Evolução Recente da Organização Espacial do Estado da Bahia. *Revista Brasileira de Geografia*. v. 51, n. 4, outubro-dezembro 1989. p. 53-70.
- SIMONI, P. O.; RODRIGUES, V e OLIVEIRA, P. P. B. Using Different Sources of Information in Automated Linear Feature Extraction from Remote Sensing Data. *Anais do V Simpósio Brasileiro de Sensoriamento Remoto*. Natal, 11-15 outubro 1988. v. 2. p. 530-536.
- SKIDMORE, Andrew K. e TURNER, Brian J. Forest Mapping Accuracies Are Improved Using a Supervised Nonparametric Classifier With SPOT Data. *Photogrammetric Engineering & Remote Sensing*. v. 54, n. 10, outubro 1988. p. 1415-1421.
- SOARES, Laura R. S. de B.; NASCIMENTO, Iuli e BA, Mamadon. Informações para o Planejamento Urbano e Regional do Distrito Federal e Entorno - A Ocupação do Solo no Eixo/Luziânia. *Anais do II Encontro Nacional de Sensoriamento Remoto Aplicado ao Planejamento Municipal*. Serra negra, 2-5 abril 1991. p. 135-139.
- SOUZA, Edilberto B. de e NERY, Carlos E. Impacto da Resolução na Classificação Automática (TM X SSR). *Anais do VI Simpósio Brasileiro de Sensoriamento Remoto*. Manaus, 24-29 junho 1990. v. 1, p. 209-213.
- STRINGER, W. J.; GROVES, J. E. e OLMSTED, C. Landsat Determined Geographic Change. *Photogrammetric Engineering & Remote Sensing*. v. 54, n. 3, março 1988. p. 347-351.
- SWAIN, P. H. e DAVIS, S. M. *Remote Sensing: the Quantitative Approach*. New York, McGraw-Hill, 1978.
- SWANN, Richard, HAWKINS, Dave, WESTWELL-HOPPER, Andrew e JOHNSTONE, William. The Potential for Automated Mapping Geocoded Digital Image Data. *Photogrammetric Engineering & Remote Sensing*. v. 54, n. 2, fevereiro 1988. p. 187-193.
- TEJWANI, Yogendra J. e JONES, Richard A. Machine Recognition of Partial Shapes Using Feature Vectors. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 15, n. 4, julho-agosto 1985. p. 504-516.
- TEOTIA, Harendra S.; CIVCO, Daniel L.; ULBRICHT, Klaus A. e KENNARD, William. Utilization of SPOT Data for Land Use/Cover Mapping and Soil/Land Classification in the Piauí State of Northeastern Brazil. *Proceedings of the Twenty-Fourth International Symposium on Remote Sensing of Environment*. Rio de Janeiro, 27-31 maio 1991. v.1. p. 231-239.

- TIKUNOV, Vladimir S. Recherches Dans le Domaine de L'Intelligence Artificielle et Systemes Experts en Geographie. *Annales de Geographie*. n. 552, marco-abril 1990. p. 129-140.
- TITCHENER, M. R. Novel Data Packing Algorithm for Improved String Matching. *IEEE Proceedings-E*. V. 133, n. 4, julho 1986, p. 185-191.
- TODD, W. e BAUMGARDNER, M. F. *Land Use Classification of Marion County, Indiana, by Spectral Analysis of Digitized Satellite Data*. Purdue, LARS Information Note 101673, 1973.
- TOGAI, Masaki e WATANABE, Hiroyuri. A VLSI Implementation of a Fuzzy-Inference Engine: Toward an Expert System on a Chip. *Information Sciences*. V. 38, 1986. p. 147-163.
- TOU, Julius T. Engineering Principles of Pattern Recognition. *Advances in Information Systems Science*. New York, Plenum, 1969. v.1. p.173-249.
- TOWNSEND, Frederick E. The Enhancement of Computer Classifications by Logical Smoothing. *Photogrammetric Engineering & Remote Sensing*. v. 52, n. 2, fevereiro 1986. p. 213-221.
- TREITZ, Paul M.; HOWARTH, Philip J. e GONG, Peng. Application of Satellite and GIS Technologies for Land-Cover and Land-Use Mapping at the Rural-Urban Fringe: a Case Study. *Photogrammetric Engineering & Remote Sensing*. v. 58, n. 4, abril 1992. p.439-448.
- TSENG, Gwo Jyh e SOOD, Arun K. Analysis of Long Image Sequence for Structure and Motion Estimation. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 19, n. 6, novembro-dezembro 1989, p. 1511-1526.
- TUYAHOV, A.J.; DAVIES, S. e HOLZ, R.K. Detection of Blight Using Remote Sensing Techniques. *Remote Sensing of Earth Resources*. v.2. 1973. p.213-226.
- UNSER, Michael e EDEN, Murray. Nonlinear Operators for Improving Texture Segmentation Based on Features Extracted by Spatial Filtering. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 20, n. 4, julho-agosto 1990. p. 804-815.
- VEDOVELLO, Ricardo e MATTOS, Juécio T. de. Zoneamento Geotécnico de Múltiplo Uso do Município de Ubatuba-SP: Uma abordagem através de Sensoriamento Remoto. *Anais do II Encontro Nacional de Sensoriamento Remoto Aplicado ao Planejamento Municipal*. Serra Negra, 2-5 abril 1991. p. 103-107.

- VENTURIERI, Adriano; FUNAKI, Rosa Sumiko e MEDEIROS, José Simeão de. Mapeamento da Cobertura Vegetal e Uso da Terra na Região de Tucuruí através da Classificação Digital Supervisionada de Imagens TM LANDSAT. *Anais do VI Simpósio Brasileiro de Sensoriamento Remoto*. Manaus, 24-29 junho 1990. v.1.p. 97-102.
- VIEIRA, I. M., CANDEIAS, A. L. B.; SANTOS, A. C. dos e HAMBURGER, D. S. Utilização de Processamento Digital de Imagens na Análise e Monitoramento da Expansão Urbana. *Anais do VI Simpósio Brasileiro de Sensoriamento Remoto*, Manaus, 24-29 junho 1990. v. 2. p. 395-403.
- VIEIRA, Ieda M. e KURKDJIAN, Maria de Lourdes N. de O. Avaliação da Expansão Urbana no Município de Ubatuba com Dados de Sensoriamento Remoto Orbital. *Anais do II Encontro Nacional de Sensoriamento Remoto Aplicado ao Planejamento Municipal*. Serra Negra, 2-5 abril 1991. p. 049-054.
- WALSH, S.J.; COOPER, J.W.; VON ESSEN, IA.e GALLAGER, K.R. Image Enhancement of Landsat thematic Mapper Data and GIS Integration for Evaluation of resource Characteristics. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 8, agosto, 1980. p. 1135-1141.
- WANG, Li e HE, D. C. A New Statistical Approach for Texture Analysis. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 1, janeiro 1990. p. 61-66.
- WANG, F. - *Integrating Expert Vision Systems and Spatial Databases by Unifying Knowledge Representation Schemes: Development in Remote Sensing Image Analysis Expert Systems and Geographical Information Systems*, Ph. D. Dissertation, University of Waterloo, Ontário, Canadá, 1989. 207p.
- WANG, Fangju. Improving Remote Sensing Image Analysis Through Fuzzy Information Representation. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 8, agosto 1990. p. 1163-1169.
- WARREN, Steven D.; JOHNSON, Mark O.; GORAN, William D. e DIERSING, V. E. An Automated, Objective Procedure for Selecting Representative Field Sample Sites. *Photogrammetric Engineering & Remote Sensing*. v. 56, n. 3, março 1990. p. 333-335.
- WATERMAN, Donald A. *A Guide to Expert Systems*. Reading, Addison-Wesley, 1986. 418p.
- WEISS, Sholom M. e KULIKOWSKI, Casimir A. *Guia Prático para Projetar Sistemas Especialistas*. Rio de Janeiro, Livros técnicos e Científicos, 1988. 170p.
- WELCH, R. Desktop Mapping with Personal Computers. *Photogrammetric Engineering & Remote Sensing*.v.55, n. 11, novembro 1989. p. 1651-1662.

- WELCH, R. e EHLERS, Manfred. Merging Multiresolution SPOT HRV and Landsat TM Data. *Photogrammetric Engineering & Remote Sensing*. v. 53, n. 3, março 1987. p. 301-303.
- WESTERLUND, F. V. *Remote Sensing for Planning: a Bibliography and Review of Literature*. Washington, University of Washington, 1972.
- WHARTON, S. A Spectral-Knowledge_Based Approach for Urban and Land-Cover Discrimination. *IEEE Transactions on Geoscience and Remote Sensing*. GE-25, n.3. 1987. p.272-282.
- WITENSTEIN, M. M. Photo Sociometrics. The Application of Aerial Photography to Urban Administration and Planning Problems. *Photogrammetric Engineering*, v. 20, n. 3, 1954. p. 410-427.
- WONG, Andrew K. C. e YOU, Manlai. Entropy and Distance of Random Graphs With Application to Structural Pattern Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. v. 7, n. 5, setembro 1985. p. 599-609.
- WRAY, J. R. Census Cities Project and Atlas of Urban and Regional Changes. *Proceedings of Third Annual Earth Resources Program*. Review, Houston, 1970 v. 01. p. 2-1 a 2-16.
- WRAY, J. R. Photo Interpretation in Urban Area Analysis. *Manual of Photographic Interpretation*. Washington, American Society of Photogrammetry, 1960. p. 667-703.
- YAGER, Ronald R. Approximate Reasoning as a Basic for Rule-Based Expert Systems. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 14, n. 4, julho-agosto 1984. p. 636-643.
- YANG, S. Hyun. Range Image Segmentation and Classification Via Split-and Merge Based on Surface Curvature. *4th International Conference on Pattern Recognition*, Cambridge, 1988. p. 58-67.
- YOUNG, J. A. T. Remote Sensing and an Experimental Geographic Information System for Environmental Monitoring, Resource Planning and Management. *International Journal of Remote Sensing*. v. 7, n. 6, 1986. p. 741-744.
- ZADEH, L.A. Fuzzy Sets. *Information Control*. v. 8, n. 3, 1965. p. 338-353.
- ZADEH, L.A. Fuzzy Algorithms. *Information Control*. v. 12, 1968. p. 94-102.
- ZADEH, L.A. Outline of a New Approach to the Analysis of Complex Systems and Decision Processes. *IEEE Transactions on Systems, Man and Cybernetics*. V. SMC-3, n. 1, janeiro, 1973. p. 28-44.

- ZAHN, Carlos Eduardo. O Processo de Urbanização: Características e Evolução. *Questões de Organização do Espaço Regional*. São Paulo, Nobel, 1983. p. 25-42.
- ZAINAL, A.J.M.; DALBY, D.H. e ROBINSON, I.S. Monitoring Marine Ecological Changes on the East Coast of Bahrain with LANDSAT TM. *Photogrammetric Engineering & Remote Sensing*. v. 59, n. 3, março 1993, p.415-421.
- ZEMANKOVA, Maria e KANDEL, Abraham. Implementing Imprecision in Information Systems. *Information Sciences*. v. 37, 1985. p. 107-141.
- ZHANG, Ming Chuan; HARALICK, Robert M. e CAMPBELL, James B. Multispectral Image Context Classification Using Stochastic Relaxation. *IEEE Transactions on Systems, Man, and Cybernetics*. v. 20, n. 1, janeiro-fevereiro 1990. p. 128-140.
- ZIMMERMANN, H. J. *Fuzzy Set Theory and Its Applications*. Boston, Kluwer-Nighoff, 1985.
- ZOBRIST, A. L. ; BRYANT, N. A. e LANDINI, A. J. IBIS - A Geographical Information System that can Use Satellite Data for urban Analysis. *URISA National Conference*. Atlanta, 1976.