

MARIA TEREZA GALEB NOGUCHI

**UM SISTEMA BASEADO EM REGRAS *FUZZY* PARA CLASSIFICAÇÃO
SUPERVISIONADA DE IMAGENS MULTIESPECTRAIS DE ALTA
RESOLUÇÃO**

**Dissertação apresentada como requisito parcial
à obtenção do grau de Mestre. Programa de
Pós-Graduação em Informática, Setor de
Ciências Exatas, Universidade Federal do
Paraná.**

Orientadora: Prof.^a Dr.^a Olga R. Pereira Bellon

CURITIBA

2004

TERMO DE APROVAÇÃO

*Deus dá a todos uma estrela.
Uns fazem da estrela um Sol.
Outros nem conseguem vê-la.*

Helena Kolody

À meu marido Mário Tatsuo Noguchi, pelo companheirismo, pelo grande apoio nos bons e nos maus momentos, e por toda a sua paciência ao ceder infindáveis horas de nosso convívio para que essa dissertação pudesse ser concluída.

À minha mãe Amélia Galeb, que desde a infância sempre me ensinou a valorizar a Educação e a ser persistente em minhas metas.

AGRADECIMENTOS

Não há palavras que expressem meu contentamento em finalizar este trabalho de pós-graduação. Muitas foram as dificuldades enfrentadas durante todo o processo de desenvolvimento desta pesquisa mas, felizmente, todas elas superadas. Por isso, primeiramente quero agradecer à Deus, pela vida e saúde e pela Sua presença constante em todos os momentos da minha vida. Por Ele ter sempre mostrado novos caminhos quando as dificuldades apareciam, transformando um sonho em realidade.

Agradeço também ao meu marido e amigo, Mário Tatsuo Noguchi, pelo amor, compreensão e incentivo em todos os momentos. Por ter acreditado nos meus sonhos oferecendo sua ajuda, ora silenciosa quando com paciência me ouviu, ora com sorrisos ou palavras de incentivo, tendo sempre atitudes de afeto que foram fundamentais nesta etapa importante de minha vida.

Aos meus pais, Abrão Galeb Filho e Amélia Galeb, pelos primeiros ensinamentos da minha vida e por todo carinho e apoio nos momentos difíceis. À minha mãe, amiga de todas as horas, dedicada e incentivadora, que esteve sempre ajudando dentro do que lhe era possível.

Aos meus irmãos, Izabel Cristina Galeb, Abrão Galeb Neto e Maria da Glória Galeb, especialmente às minhas “maninhas”, pela amizade, por partilhar comigo de várias situações desse desafio de minha vida, através de apoio e motivação constante.

À minha orientadora, Prof^a.Dr^a. Olga Regina Pereira Bellon, pela escolha acertada do tema principal, pelo auxílio na elaboração desse estudo e sobretudo por toda a confiança em mim depositada. Também por sua forma exigente e crítica de conduzir o trabalho, pela paciência e pelo inestimável apoio nas etapas do desenvolvimento deste estudo.

Especialmente agradeço ao Prof. Msc. Hideo Araki por sua forma tranqüila, mas eficiente de guiar-me nesta jornada. Pela disponibilidade e tempo dedicados, nos quais tivemos preciosas conversas que definiram a diretriz da aplicação deste trabalho. Também estou grata pelo incentivo constante, pela indicação de excelentes referências bibliográficas, pelo esclarecimento de dúvidas através dos ensinamentos transmitidos e pelos seus inúmeros comentários, sugestões e recomendações, sempre úteis e experientes, que melhoraram, em muito, o presente texto. E, pela sua presença na defesa desta dissertação.

Ao Prof. Dr. Alexandre Ibrahim Direne, pelo exemplo de profissional dedicado e comprometido com o Programa de Pós-Graduação. Pelos bons conselhos, pela sua disponibilidade irrestrita sempre que procurado, por sua disposição em ajudar sempre e pelas palavras de incentivo, grande empenho e importante auxílio prestado nas diversas fases deste projeto de pesquisa. Pela sua participação na defesa da proposta e do trabalho final, colaborando com críticas e sugestões, que com certeza contribuíram para ampliar a qualidade deste trabalho.

Ao Prof. Dr. Hélio Pedrini, pelos importantes comentários e sugestões efetuadas durante a apresentação da proposta e pela disposição em ajudar sempre.

Ao Prof. Dr. Luciano Silva, membro da banca examinadora, pelo rigor na revisão do texto, auxiliando no aprimoramento deste trabalho com críticas e sugestões.

À todos os professores do curso de Programa de Pós-Graduação em Informática da Universidade Federal do Paraná, dedicados à arte de ensinar, pela contribuição para o meu progresso acadêmico.

Aos funcionários do Departamento de Informática da Universidade Federal do Paraná pela atenção dedicada e, em especial, aos prestativos secretários José Carlos Pereira e Jucélia Miecznikowski, pela amizade e por toda ajuda prestada ao longo desta jornada.

Ao amigo Msc. Mário Jorge Schneider, que compartilhou experiências do curso.

À Lenita Kozak, bióloga responsável pelo Centro Ambiental Casa Branca, localizado em Rio Negro no Paraná, pelo auxílio prestado com relação às informações sobre a vegetação típica da região de estudo e indicação de pontos de referência na área da imagem.

À PARANACIDADE pela disponibilização da imagem Ikonos.

Portanto, a presente dissertação não foi fruto de uma conquista individual, mas da ajuda, do entusiasmo, da compreensão e da boa vontade de diversas pessoas que estiveram sempre presentes nesta etapa da minha vida. Por isso, agradeço sinceramente à todos os colegas, amigos e familiares que contribuíram, de forma direta ou indireta, para a realização deste trabalho.

SUMÁRIO

LISTA DE FIGURAS	ix
LISTA DE TABELAS	xi
RESUMO	xii
ABSTRACT	xiii
1. INTRODUÇÃO	1
1.1. MOTIVAÇÕES.....	1
1.2. OBJETIVOS.....	3
1.2.1. Objetivo Geral.....	3
1.2.2. Objetivos Específicos.....	4
1.3. CONTRIBUIÇÕES.....	4
1.4. ESTRUTURA DA DISSERTAÇÃO.....	5
2. FUNDAMENTAÇÃO TEÓRICA	6
2.1. SENSORIAMENTO REMOTO.....	6
2.1.1. Definição.....	6
2.1.2. Energia Eletromagnética.....	7
2.1.3. Espectro Eletromagnético.....	8
2.1.4. Interações da Energia na Atmosfera.....	10
2.1.5. Interações da Energia com a Superfície Terrestre.....	12
2.1.6. Sistemas Sensores.....	15
2.1.7. Comportamento Espectral dos Alvos Naturais.....	24
2.1.8. Comportamento Espectral dos Objetos Artificiais.....	29
2.1.9. Fatores que Interferem no Comportamento Espectral dos Objetos da Superfície.....	31
2.1.10. Satélite de Alta Resolução Ikonos.....	31
2.2. PROCESSAMENTO DIGITAL DE IMAGENS.....	33
2.2.1. Definição.....	33
2.2.2. Representações Gráficas.....	33
2.2.3. Etapas.....	36
2.2.4. Pré-Processamento.....	37
2.2.5. Realce.....	39
2.2.6. Classificação.....	46
2.2.7. Avaliação da Classificação.....	56
2.3. LÓGICA NEBULOSA.....	59
2.3.1. Definição.....	59
2.3.2. Conjuntos Nebulosos.....	59
2.3.3. Sistemas Nebulosos.....	71
2.4. APLICAÇÃO DA TEORIA NEBULOSA A CLASSIFICAÇÃO DE IMAGENS.....	78
2.4.1. Sistema Nebuloso: <i>An Explicit Fuzzy Supervised Classification Method for Multispectral Remote Sensing Images</i>	79
2.4.2. Sistema Nebuloso: <i>Fuzzy Rule-Based Classification of Remotely Sensed Imagery</i>	81
2.4.3. Sistema Nebuloso: <i>Fuzzy Logic System for Road Identification Using Ikonos Images</i>	82
2.4.4. Sistema Nebuloso: <i>A Fuzzy Classification Approach for High-Resolution Multispectral Data Over Urban Areas</i>	85
3. METODOLOGIA	90
3.1. MATERIAIS E INFRA-ESTRUTURA.....	90
3.1.1. Área de Estudo.....	90
3.1.2. Hardware e Software.....	92
3.1.3. Técnicas Utilizadas.....	97
3.2. DESENVOLVIMENTO DO MÉTODO PROPOSTO.....	105
3.2.1. Pré-Processamento.....	107
3.2.2. Geração dos Índices.....	107
3.2.3. Seleção das Amostras.....	113
3.2.4. Criação do Sistema Nebuloso.....	113
3.2.5. Verdade de Terreno.....	119
4. RESULTADOS	120
4.1. ANÁLISE DOS RESULTADOS.....	122
4.1.1. Análise Visual.....	122

4.1.2. Análise Estatística.....	126
5. DISCUSSÃO E CONCLUSÕES.....	129
5.1. CONCLUSÕES.....	129
5.2. TRABALHOS FUTUROS.....	131
REFERÊNCIAS BIBLIOGRÁFICAS.....	132
APÊNDICE – RELAÇÃO DOS REGISTROS DE AMOSTRAS DE VERDADE DE TERRENO.....	134

LISTA DE FIGURAS

FIGURA 2.1 – SISTEMA DE SENSORIAMENTO REMOTO.....	6
FIGURA 2.2 – ONDA ELETROMAGNÉTICA.....	8
FIGURA 2.3 – ESPECTRO ELETROMAGNÉTICO.....	9
FIGURA 2.4 – SISTEMA DE CORES RGB.....	10
FIGURA 2.5 – INTERAÇÕES DA ENERGIA ELETROMAGNÉTICA COM A ATMOSFERA.....	11
FIGURA 2.6 – TRANSMISSÃO ATMOSFÉRICA.....	12
FIGURA 2.7 – INTERAÇÕES DA ENERGIA ELETROMAGNÉTICA COM A SUPERFÍCIE TERRESTRE.....	13
FIGURA 2.8 – REPRESENTAÇÃO DE UM SENSOR PASSIVO E ATIVO.....	16
FIGURA 2.9 – IMAGEM IKONOS: BANDAS DO VISÍVEL: AZUL, VERDE E VERMELHA E A COMPOSIÇÃO RGB.....	18
FIGURA 2.10 – REPRESENTAÇÃO DO CAMPO INSTANTANEO DE VISADA (IFOV)	20
FIGURA 2.11 – EXEMPLO DA RESOLUÇÃO ESPACIAL LANDSAT X IKONOS.....	21
FIGURA 2.12 – CURVAS DE REFLECTÂNCIA ESPECTRAL PARA VEGETAÇÃO SADIA.....	25
FIGURA 2.13 – CURVAS DE REFLECTÂNCIA ESPECTRAL PARA UMA FOLHA DE PLANTA QUE PROGRIDE DE UM ESTADO SAUDÁVEL PARA DIFERENTES ESTÁGIOS DE DANO.....	26
FIGURA 2.14 – CURVAS DE REFLECTÂNCIA ESPECTRAL PARA SOLO.....	26
FIGURA 2.15 – CURVAS DE REFLECTÂNCIA ESPECTRAL PARA ÁGUA.....	28
FIGURA 2.16 – CURVAS DE REFLECTÂNCIA PARA ÁREA URBANA.....	30
FIGURA 2.17 – EXEMPLOS DE HISTOGRAMAS.....	34
FIGURA 2.18 – REPRESENTAÇÃO DE UM VETOR DE ATRIBUTOS.....	35
FIGURA 2.19 – ESPAÇO DE ATRIBUTOS.....	35
FIGURA 2.20 – PASSOS FUNDAMENTAIS EM PROCESSAMENTO DE IMAGENS DIGITAIS.....	36
FIGURA 2.21 – ETAPAS DO PROCESSAMENTO DE IMAGENS DIGITAIS EM SENSORIAMENTO REMOTO.....	36
FIGURA 2.22 – EXEMPLO DE UM AUMENTO LINEAR DE CONTRASTE DA IMAGEM.....	40
FIGURA 2.23 – EXEMPLO DA JANELA MÓVEL PARA FILTRAGEM DE UMA IMAGEM POR CONVOLUÇÃO.....	41
FIGURA 2.24 – EXEMPLO DAS CONDIÇÕES DE ILUMINAÇÃO DE UMA CENA.....	44
FIGURA 2.25 – REPRESENTAÇÃO DA CLASSIFICAÇÃO SUPERVISIONADA.....	49
FIGURA 2.26 – PIXELS REPRESENTANDO SELEÇÃO DE LOCAIS DE TREINAMENTO EM UM ESPAÇO DE ATRIBUTOS.....	50
FIGURA 2.27 – CONTORNOS EQUIPROVÁVEIS DEFINIDOS PELA ESTRATÉGIA DO CLASSIFICADOR DA MÁXIMA VEROSSIMILHANÇA.....	51
FIGURA 2.28 – REPRESENTAÇÃO DA CLASSIFICAÇÃO NÃO SUPERVISIONADA.....	53
FIGURA 2.29 – EXEMPLO DE AGRUPAMENTO ISODATA.....	54
FIGURA 2.30 – EXEMPLO DE CLASSIFICADOR DE ÁRVORE DE DECISÃO.....	55
FIGURA 2.31 - REPRESENTAÇÃO DA PERTINÊNCIA DE UM PIXEL A UMA DETERMINADA CLASSE.....	61
FIGURA 2.32 - REPRESENTAÇÃO DE CLASSE ESPECTRAIS DISTINTAS E SEMELHANTES.....	62
FIGURA 2.33 – REPRESENTAÇÃO DOS CONJUNTOS FUZZY DA TABELA 2.4.....	63
FIGURA 2.34 – REPRESENTAÇÃO DOS TIPOS DE FUNÇÕES DE PERTINÊNCIA NEBULOSAS.....	66
FIGURA 2.35 – REPRESENTAÇÃO DO COMPLEMENTO DE UM CONJUNTO NEBULOSO.....	68
FIGURA 2.36 – REPRESENTAÇÃO DA INTERSECÇÃO DE CONJUNTOS NEBULOSOS.....	69
FIGURA 2.37 – REPRESENTAÇÃO DA UNIÃO DE CONJUNTOS NEBULOSOS.....	71
FIGURA 2.38 – REPRESENTAÇÃO DO CONJUNTO NEBULOSO ESCURO E MUITO ESCURO.....	73
FIGURA 2.39 – ETAPAS DE UM SISTEMA NEBULOSO.....	74
FIGURA 2.40 – REPRESENTAÇÃO DA CLASSIFICAÇÃO HARD E DA CLASSIFICAÇÃO UTILIZANDO LÓGICA NEBULOSA.....	79
FIGURA 3.1 – MAPA DE LOCALIZAÇÃO DA CIDADE DE RIO NEGRO NO PARANÁ.....	90
FIGURA 3.2 – MAPA DE LOCALIZAÇÃO DA CIDADE DE MAFRA EM SANTA CATARINA.....	91
FIGURA 3.3 – IMAGEM MULTIESPECTRAL UTILIZADA NA CLASSIFICAÇÃO.....	93
FIGURA 3.4 – CLASSIFICAÇÃO DO ISODATA – ÁREA 01.....	99
FIGURA 3.5 – CLASSIFICAÇÃO DO ISODATA – ÁREA 02.....	100
FIGURA 3.6 – CLASSIFICAÇÃO DO ISODATA COM 5 CLUSTERS.....	100
FIGURA 3.7 – MAPA TEMÁTICO OBTIDO DA APLICAÇÃO DO MÉTODO MAXVER.....	104

FIGURA 3.8 –FLUXOGRAMA DO MÉTODO PROPOSTO.....	106
FIGURA 3.9 –HISTOGRAMA DAS BANDAS ORIGINAIS.....	108
FIGURA 3.10 –IMAGEM E HISTOGRAMA DO ÍNDICE NDVI.....	109
FIGURA 3.11 –IMAGEM E HISTOGRAMA DO ÍNDICE NAND.....	110
FIGURA 3.12 –IMAGEM E HISTOGRAMA DO ÍNDICE INDAGU.....	110
FIGURA 3.13 –IMAGEM E HISTOGRAMA DO ÍNDICE INDFLO.....	111
FIGURA 3.14 –IMAGEM E HISTOGRAMA DO ÍNDICE INDEST.....	112
FIGURA 3.15 –VARIÁVEIS DE ENTRADA E SAÍDA NEBULOSAS.....	115
FIGURA 3.16 –REPRESENTAÇÃO DAS REGRAS (COM NANDA) EM ÁRVORE DE DECISÃO.....	117
FIGURA 3.17 –REPRESENTAÇÃO DAS REGRAS (SEM NANDA) EM ÁRVORE DE DECISÃO.....	118
FIGURA 3.18 – LOCALIZAÇÃO DAS AMOSTRAS DE VERDADE DE TERRENO.....	119
FIGURA 4.1 – IMAGEM CLASSIFICADA PELO MÉTODO PROPOSTO UTILIZANDO O ÍNDICE NANDA.....	121
FIGURA 4.2 – IMAGEM CLASSIFICADA PELO MÉTODO PROPOSTO SEM A UTILIZAÇÃO DO ÍNDICE NANDA.....	121
FIGURA 4.3 – COMPARAÇÃO DO RESULTADO DA CLASSIFICAÇÃO – ÁREA 1 (ISODATA COM 05 CLUSTERS, MAXVER E MÉTODO PROPOSTO).....	124
FIGURA 4.4 – COMPARAÇÃO DO RESULTADO DA CLASSIFICAÇÃO – ÁREA 2 (ISODATA COM 05 CLUSTERS, MAXVER E MÉTODO PROPOSTO).....	125

LISTA DE TABELAS

TABELA 2.1 – CARACTERÍSTICAS DOS SATÉLITES IKONOS.....	32
TABELA 2.2 - REDUÇÃO DA ILUMINAÇÃO DE CENA EFETUADA POR RAZÃO ESPECTRAL.....	44
TABELA 2.3 – REPRESENTAÇÃO DA MATRIZ DE ERRO.....	56
TABELA 2.4 - CONJUNTOS NÉBULOSOS DE PIXELS DA BANDA A.....	62
TABELA 2.5 – T-NORMAS E T-CONORMAS DUAIS.....	71
TABELA 3.1 – CLASSES ESPECTRAIS DETECTADAS COM O MÉTODO ISODATA.....	98
TABELA 3.2 – RESULTADO DA DIVERGÊNCIA TRANSFORMADA.....	102
TABELA 3.3 – MATRIZ DE ERRO DA CLASSIFICAÇÃO DO CONJUNTO DE PIXELS DE TREINAMENTO.....	103
TABELA 3.4 – INTERVALO DE VALORES DOS PIXELS APÓS A CORREÇÃO ATMOSFÉRICA.....	107
TABELA 3.5 – RESUMO DOS VALORES DE LIMIAR.....	115
TABELA 3.6 – RESUMO DOS VALORES DO PARÂMETRO 1.....	115
TABELA 3.7 – RESUMO DOS VALORES DO PARÂMETRO 2.....	116
TABELA 4.1 – MATRIZ DE ERRO DA CLASSIFICAÇÃO DAS AMOSTRAS DE VERDADE DE TERRENO NO MAXVER COM SOLO EXPOSTO.....	126
TABELA 4.2 – EXATIDÃO GLOBAL, DO PRODUTOR E USUÁRIO (TABELA 4.1)	127
TABELA 4.3 – MATRIZ DE ERRO DA CLASSIFICAÇÃO DAS AMOSTRAS DE VERDADE DE TERRENO NO MAXVER SEM SOLO EXPOSTO.....	127
TABELA 4.4 – EXATIDÃO GLOBAL, DO PRODUTOR E USUÁRIO (TABELA 4.3)	127
TABELA 4.5 – MATRIZ DE ERRO DA CLASSIFICAÇÃO DAS AMOSTRAS DE VERDADE DE TERRENO NO MÉTODO PROPOSTO.....	128
TABELA 4.6 – EXATIDÃO GLOBAL, DO PRODUTOR E USUÁRIO (TABELA 4.5)	128

RESUMO

Este estudo descreve um sistema baseado em regras nebulosas para classificação supervisionada de imagens multiespectrais de alta resolução. O novo método utiliza nas variáveis de entrada combinações de bandas, como o NDVI, que destacam determinados tipos de feições terrestres. As funções de pertinência das variáveis de entrada nebulosas são definidas a partir de limiares obtidos de amostras previamente selecionadas. Estas variáveis são utilizadas para gerar as regras nebulosas de forma a detectar na imagem Ikonos as seguintes variáveis de saída: vegetação rasteira, vegetação arbórea, água, edificações e estrada. A imagem classificada pelo método proposto é comparada com os resultados obtidos pelo método da máxima verossimilhança, sendo que o sistema nebuloso com apenas cinco regras apresenta melhores resultados na classificação.

Palavras-chave: Sensoriamento remoto, imagem de alta resolução, satélite Ikonos, classificação, sistema baseado em regras *fuzzy*.

ABSTRACT

This study describes a fuzzy rule-based system for supervised classification of multispectral high resolution images. The new method uses in the input variables combinations of bands, like NDVI, that detaching certain types of terrestrial features. The membership functions of the fuzzy input variables are defined starting from obtained thresholds of samples selected previously. These variables are used to generate the fuzzy rules in way to detect in the image Ikonos the following output variables: low vegetation, forest, water, buildings and road. The classified image by the proposed method is compared with the results generated by the method of maximum likelihood, and the system with only five fuzzy rules generated better results in the classification.

Keywords: Remote sensing, image of high resolution, satellite Ikonos, classification, fuzzy rule-based system.

1. INTRODUÇÃO

1.1. MOTIVAÇÕES

As imagens digitais geradas pelos sensores remotos de alta resolução (Ikonos), abrangem muito mais detalhes, do que sensores anteriormente existentes (Landsat), sendo possível visualizar os elementos componentes de uma cena urbana como: árvores, edificações, estradas, dentre outros (KUO et al., 2001).

As imagens de alta resolução encontram grande demanda por parte dos usuários finais (KOK et al., 1999), que são interessados em resolução de imagem que os ajude a observar e monitorar seus objetos específicos de interesse. Para obter estas informações utilizadas no monitoramento de recursos naturais e mapeamento de uso do solo, é necessário o uso de técnicas de classificação de imagens.

Os humanos tem a capacidade impressionante de efetuar abstrações e assim fazer um satisfatório trabalho de análise e interpretação de dados de sensoriamento remoto, porém, ao tentar automatizar o processo a ser feito pelo computador, percebe-se que não é uma tarefa trivial, tratando-se de um processo complexo. As características das imagens de alta resolução citadas a seguir, retratam algumas dificuldades encontradas na manipulação das mesmas:

a) O incremento na resolução radiométrica, de 256 níveis de cinza do sensor do satélite Landsat para 2048 do sensor do Ikonos, permite capturar uma variação maior de reflectância e, elementos que anteriormente apresentavam o mesmo tom de cinza, podem ser diferenciados com os novos sensores;

b) O aumento na resolução espacial, de 30 metros do sensor do Landsat para 1 metro na imagem pancromática e 4 metros na multiespectral do sensor do Ikonos, gera objetos compostos por vários *pixels*, sendo que nas imagens do Landsat, um *pixel* contém vários objetos. Os *pixels* que são compostos por mais de um tipo de cobertura de solo são chamados de *pixels* "mistura", sendo que estes poderão ocorrer mesmo nas imagens de alta resolução;

c) A redução na resolução espectral, onde o Ikonos possui 4 bandas multiespectrais, enquanto o Landsat possui 7 bandas. Esta redução no número de bandas, dificulta a separabilidade entre vários tipos de cobertura do solo.

Os problemas relatados como a separabilidade das classes devido ao aumento da resolução radiométrica e redução da resolução espectral; a existência de *pixels* “mistura”, mesmo com o aumento da resolução espacial e as coberturas terrestres que possuem grande semelhança espectral, dentre outros, tornam necessário o desenvolvimento de métodos adicionais de classificação, que atentem para estes detalhes, gerando um bom resultado na classificação.

Várias técnicas para extração de informação de dados de sensoriamento remoto tem surgido nas duas últimas décadas. A técnica mais popular é o método da máxima verossimilhança (MELGANI et al., 2000), o qual é geralmente aplicado na classificação de imagens de média resolução espacial. Mas, segundo SHACKELFORD e DAVIS (2002), os métodos de classificação tradicionais, tais como a máxima verossimilhança que utilizam apenas as características espectrais são incapazes de diferenciar de forma acurada classes que possuem semelhança espectral tais como: grama/árvore e estradas/edificações, sendo necessária a implementação de novos métodos que visem classificar de forma mais acurada as imagens de alta resolução.

A teoria *fuzzy* também chamada teoria nebulosa tem se destacado cada vez mais na área de processamento de imagens, pois proporciona uma ferramenta satisfatória na representação de incertezas que surgem em segmentação ou classificação, sendo possível através dela modelar a atividade de percepção dos seres humanos. Através da teoria nebulosa as incertezas podem ser propagadas ao próximo nível lógico mais alto de um determinado sistema que retém a informação, em vez de ser forçado a chegar prematuramente a uma decisão que é obrigatória em um processo convencional (CHENG et al., 2001).

Em um sistema nebuloso não há a necessidade de se assumir nenhuma distribuição específica de classes de cobertura, como no caso do método da máxima verossimilhança, onde consideram-se as classes de cobertura como sendo normalmente distribuídas (BÁRDOSSY e

SAMANIEGO, 2002). Além disso, as regras de lógica nebulosa garantem a transparência das regras de decisão, permitindo a combinação de diversas características (KOK et al., 1999).

A maioria das pesquisas relacionadas à classificação supervisionada baseada em regras nebulosas são realizadas considerando as características espectrais das imagens, nas quais as funções de pertinência das variáveis de entrada nebulosas são obtidas de valores estatísticos das amostras de treinamento das bandas, como descrito em MELGANI et al. (2000) e BÁRDOSSY e SAMANIEGO (2002).

A utilização de um sistema baseado em regras nebulosas tem demonstrado ser uma técnica eficaz para representar as diversas características das imagens. Desta forma, este tipo de técnica emerge como uma alternativa vantajosa aos classificadores baseados em conceitos estatísticos, uma vez que além de sua facilidade de implementação, pouca informação prévia sobre as estatísticas dos dados a serem classificados é exigida.

1.2. OBJETIVOS

1.2.1. Objetivo Geral

Este estudo apresenta o desenvolvimento de um novo método para classificação de imagens multiespectrais de alta resolução. Este método abrange um sistema baseado em regras nebulosas aplicadas sobre uma imagem do satélite Ikonos com resolução espacial de 4 metros.

Na abordagem proposta, desenvolve-se uma técnica de classificação supervisionada que abrange regras nebulosas considerando as características espectrais. Mas, diferentemente de outros sistemas nebulosos já implementados, as funções de pertinência das variáveis de entrada nebulosas não são obtidas de valores estatísticos das amostras de treinamento das bandas.

As variáveis de entrada e suas respectivas funções de pertinência são obtidas de amostras de treinamento de índices, isto é, imagens razão (*ratio images*), obtidas de divisões

entre as quatro bandas multiespectrais, visando destacar determinadas feições. Os índices utilizados são: NDVI, para destacar vegetação; IndAgu, para destacar água; IndFlo, para destacar vegetação arborea e IndEst, para destacar estrada.

As imagens razão ou índices são combinados através das regras nebulosas, definindo para cada classe as características mais adequadas para distinguí-las. Através da execução das regras nebulosas procura-se identificar determinados tipos de cobertura de solo existentes na imagem, os quais definem as variáveis de saída: vegetação rasteira, vegetação arborea, água, edificações e estrada.

1.2.2. Objetivos Específicos

Os objetivos específicos do estudo são descritos a seguir:

- Utilização de razões espectrais chamadas de índices, obtidas de combinações das quatro bandas multiespectrais da imagem, de forma a destacar determinados tipos de feições terrestres;
- Criação das funções de pertinência das variáveis de entrada a partir dos índices gerados;
- Análise do desempenho da utilização de regras nebulosas na classificação de imagens;
- Coleta de verdade de terreno através de visitas a campo, de forma a efetuar uma análise visual das imagens classificadas;
- Comparação dos resultados obtidos em termos de melhora na identificação de determinados tipos de cobertura com relação a classificação gerada pelo método da máxima verossimilhança, visto que este foi o método utilizado para comparar os sistemas nebulosos dos trabalhos analisados.

1.3. CONTRIBUIÇÕES

Este trabalho abrange explicações sobre a teoria nebulosa, proporcionando um

entendimento dos princípios desta teoria para indivíduos que desejam aplicar a mesma em processamento de imagens ou qualquer outra área desejada.

É desenvolvido um novo método de classificação supervisionada que abrange regras nebulosas considerando as características espectrais, porém, com um diferencial no processo de criação das variáveis de entrada. Os parâmetros para gerar estas variáveis são obtidos das amostras dos índices ou imagens razão (*ratio images*) que visam destacar determinadas feições. As imagens razão ou índices são combinados através das regras nebulosas, definindo para cada classe as características mais adequadas para distinguí-las.

Dentre os índices utilizados, IndEst e IndFlo foram criados para o método a partir de diversos experimentos realizados para destacar respectivamente estrada e vegetação arborea.

Com o experimento desta nova técnica de classificação, utilizando as regras nebulosas, procura-se classificar de forma acurada as imagens de alta resolução, gerando informações mais confiáveis em atividades como o monitoramento de recursos naturais e mapeamento de uso do solo.

1.4. ESTRUTURA DA DISSERTAÇÃO

Esta dissertação está organizada em 5 capítulos. O Capítulo 1 apresenta o problema a ser solucionado, os objetivos do trabalho e suas principais contribuições. No Capítulo 2 faz-se uma revisão da literatura relatando os conceitos principais de sensoriamento remoto; processamento de imagens, com enfoque na classificação de imagens e a lógica nebulosa, sendo também relatados estudos que utilizaram sistemas nebulosos na classificação de imagens de sensoriamento remoto. O Capítulo 3 descreve em detalhes o desenvolvimento do método proposto. No Capítulo 4 relatam-se os resultados obtidos e sua respectiva análise. E, finalmente, no Capítulo 5 são apresentadas as conclusões do trabalho e as propostas de trabalhos futuros.

2. FUNDAMENTAÇÃO TEÓRICA


Este capítulo aborda resumidamente os tópicos teóricos que são úteis na sequência deste trabalho, sendo: sensoriamento remoto, processamento de imagens e teoria nebulosa. Em seguida traz uma síntese de aplicações baseadas em sistemas nebulosos na classificação de imagens de sensoriamento remoto.

2.1. SENSORIAMENTO REMOTO

2.1.1. Definição

Segundo LILLESAND e KIEFER (1994), sensoriamento remoto é a ciência e a arte de se obter informações sobre determinado alvo (objetos, áreas ou fenômenos), através da análise dos dados adquiridos por um dispositivo (ex.: olho humano, máquina fotográfica) que não esteja em contato com o alvo sob investigação. Um sistema de sensoriamento remoto que utiliza a energia eletromagnética pode ser visualizado na Figura 2.1., onde destacam-se alguns componentes básicos como: a fonte de energia; a atmosfera; o alvo e o sensor (CURRAN, 1992).

FIGURA 2.1 – SISTEMA DE SENSORIAMENTO REMOTO



A fonte emite a energia que se propaga pela atmosfera atingindo o alvo, sendo representada na Figura 2.1. pelo Sol. O alvo absorve e/ou reflete porções de energia (que atingem o sensor), neste caso é representado pelos tipos de cobertura terrestre como: floresta, rios, pastagens, solo exposto, rodovia e área urbana. O sensor remoto é um dispositivo inserido em uma plataforma (ex.: avião ou satélite) que registra a energia refletida ou emitida pelo alvo, gerando informações que serão processadas para posterior análise e interpretação.

De acordo com o escopo deste trabalho, nos tópicos seguintes serão enfatizados os sensores que trabalham em função da energia eletromagnética, esclarecendo pontos fundamentais do comportamento desta energia em relação à atmosfera e ao alvo.

2.1.2. Energia Eletromagnética

As formas de energia eletromagnética podem ser: luz visível, ondas de rádio, microondas, radiação infravermelha, raios ultravioleta, raio-x e raios gama. A energia eletromagnética é associada a flutuações de energia na forma de onda que viajam através do espaço em uma velocidade constante ("velocidade da luz"), abrangendo um campo elétrico e magnético associados em um modelo de onda harmônico e senoidal (Figura 2.2). Pelo fato da velocidade ser constante, a onda é caracterizada somente pela sua frequência e comprimento, sendo descrita pela equação da teoria básica de ondas.

$$v = f * \lambda \quad (2.1)$$

Onde:


v = velocidade da onda: constante que abrange a "velocidade da luz" (aproximadamente 300.000 km/s);

f = frequência da onda: número de ciclos por segundo passando por determinado ponto;

λ (lâmbda) = comprimento de onda: distância entre dois picos sucessivos

Na Figura 2.2 é representada uma onda eletromagnética, constituída por uma onda elétrica senoidal (E) e uma onda magnética similar (M), perpendiculares à direção de propagação.

FIGURA 2.2 – ONDA ELETROMAGNÉTICA



FONTE: Adaptado de LILLESAND e KIEFER, 1994

O Sol é a principal fonte de energia eletromagnética disponível para sensoriamento remoto na superfície terrestre. Entretanto, toda matéria que possua uma temperatura absoluta acima de zero (0° K ou -273° C), continuamente emite energia eletromagnética. Portanto, objetos terrestres são também fontes de energia que podem gerar uma grande variedade de ondas eletromagnéticas.

2.1.3. Espectro Eletromagnético

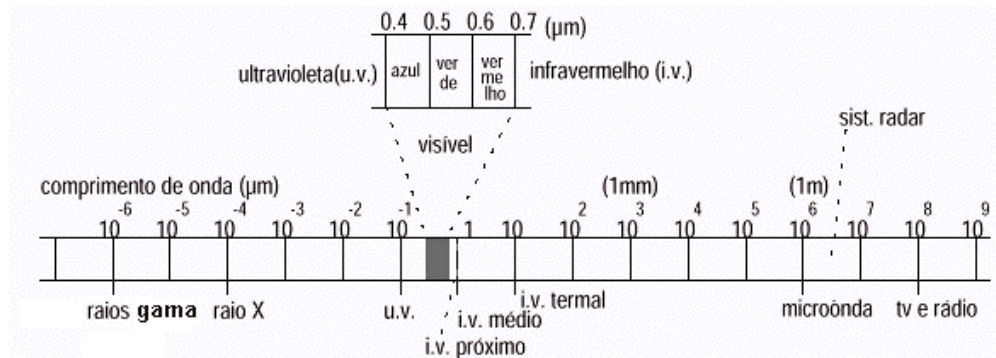
O conjunto de todos os comprimentos de ondas compõe o espectro eletromagnético (Figura 2.3). Estas ondas são geralmente classificadas segundo o seu comprimento, sendo catalogadas em grupos ou regiões com características semelhantes sendo: raios gama, raios-x, raios ultravioleta, luz visível, radiação infravermelha (próximo, médio e termal), microondas e ondas de rádio. A unidade mais utilizada para medir o comprimento de onda ao longo do espectro é o micrômetro (μm), que equivale a $1 \times 10^{-6} m$. Na Figura 2.3 é ilustrado o espectro eletromagnético com os respectivos intervalos de onda.

Os raios gama (Figura 2.3) são gerados por átomos radioativos e explosões nucleares, possuindo maior poder de penetração do que os raios-X. Os raios gama são utilizados em aplicações na medicina e em tomadas de imagens do universo, de forma a

fornecer importantes informações sobre a vida e morte de estrelas e outros processos no universo.

Os raios-X (Figura 2.3) são ondas de alta energia que têm grande penetração, possuindo diversas aplicações na medicina.

FIGURA 2.3 – ESPECTRO ELETROMAGNÉTICO



FONTE: LILLESAND e KIEFER, 1994

A faixa ultravioleta (UV) (Figura 2.3) abrange uma porção estreita do espectro antes da região do visível. Essas ondas contidas na luz do Sol podem queimar a pele, mas têm sua utilização em observatórios de astronomia.


A Terra é iluminada naturalmente através da energia eletromagnética do Sol. O pico de energia solar está no intervalo de comprimento de onda de luz visível. Porém, a porção do espectro que corresponde ao "visível" (Figura 2.3) é extremamente pequena, assim como a sensibilidade espectral do olho humano, que abrange aproximadamente de 0.4 a 0.7 μm . A cor "azul" é encontrada próxima do intervalo de 0.4 a 0.5 μm , "verde" de 0.5 a 0.6 μm e "vermelho" de 0.6 a 0.7 μm (LILLESAND e KIEFER, 1994).

O olho humano, de acordo com as teorias mais recentes, é sensível à luz em três colorações básicas: vermelho, verde e azul. O sistema RGB: *red, green e blue* (Figura 2.4), utiliza estas cores como primárias, as quais são combinadas para gerar as demais cores.

Após a região do visível, em uma larga faixa, são encontradas três categorias diferentes de ondas do infravermelho (IV): infravermelho próximo (de 0.7 a 1.3 μm), infravermelho médio (de 1.3 a 3 μm) e infravermelho termal (acima de 3 μm) (LILLESAND

e KIEFER,1994). Através do IV termal, sensores a bordo de satélites ou aviões podem gerar imagens com o objetivo de detectar incêndios em florestas.

FIGURA 2.4 – SISTEMA DE CORES RGB



O comprimento de onda mais longo (1 mm para 1 m) do espectro, corresponde as microondas (Figura 2.3). Em um forno de microondas, as microondas geradas são usadas para aquecimento, no qual os alimentos absorvem a energia das ondas e se aquecem. Microondas são emitidas pela terra, carros, aviões e atmosfera, podendo ser detectadas para dar informação sobre a temperatura dos objetos que as emitem.

As ondas de rádio (Figura 2.3) são usadas para transmitir sinais de rádio e de TV. As ondas de rádio FM (com 3 metros) são mais curtas do que as ondas AM (com 400 metros). As ondas de rádio também são usadas para criar imagens, sendo que, com comprimentos de onda de poucos centímetros podem ser transmitidas por um satélite ou antena em um avião. As ondas refletidas podem ser usadas para gerar uma imagem da superfície da terra no escuro ou através de nuvens.


Devido ao olho humano estar limitado a uma pequena parte do espectro eletromagnético total, os vários tipos de sistemas sensores (óptico, termal ou radar) utilizam também a energia fora do intervalo do visível, podendo abranger uma ou mais regiões como: IV próximo, IV médio, IV termal e as microondas.

2.1.4. Interações da Energia na Atmosfera

A atmosfera é composta de gases como gás carbônico, oxigênio, ozônio, nitrogênio e argônio e, principalmente vapor de água e aerossóis. Segundo LILLESAND E KIEFER

(1994), a energia eletromagnética, em sua jornada até o alvo, sofre interferência do efeito atmosférico (Figura 2.5) através de duas formas: a absorção que elimina luminosidade e a dispersão que acrescenta luminosidade. Estes processos introduzem modificações, às vezes muito severas, na energia originalmente propagada entre a cobertura terrestre e o sensor.

FIGURA 2.5 – INTERAÇÕES DA ENERGIA ELETROMAGNÉTICA COM A ATMOSFERA




Os componentes atmosféricos que são efetivos absorventes de energia solar são: vapor de água, gás carbônico e ozônio. Deste último, pode-se destacar a absorção da energia ultravioleta perigosa para a pele. Cada um dos gases citados tende a absorver energia em determinados comprimentos de onda, tendo alguns intervalos quase que absorvidos completamente. Os sensores utilizados na observação da atmosfera (meteorológicos) detectam energia onde a absorção atmosférica é alta. Os sensores que observam a superfície terrestre são projetados para detectar energia nas "janelas atmosféricas" (Figura 2.6), isto é, regiões do espectro em que a atmosfera permite a passagem de energia, na qual a absorção é mínima e, reciprocamente, a transmissão é alta.

Quando a concentração dos agentes de dispersão é alta, gera-se o efeito visual chamado de neblina, o qual aumenta o brilho global de uma cena e reduz o contraste entre diferentes materiais da superfície. A dispersão pode ser dividida em: Rayleigh, Mie e não-seletiva. Estes processos conduzem à formação da energia difusa, onde uma porção de energia volta para o espaço e uma porção alcança a superfície. A energia que não se dispersou é chamada de energia direta. Uma propriedade importante dos comprimentos de onda longos

utilizados na região das microondas, é que eles não são suscetíveis à dispersão atmosférica, podendo penetrar em cobertura de nuvens, neblina, exceto em casos de chuva forte.

FIGURA 2.6 – TRANSMISSÃO ATMOSFÉRICA



FONTE: Adaptado de LILLESAND e KIEFER, 1994

2.1.5. Interações da Energia com a Superfície Terrestre

Segundo LILLESAND E KIEFER (1994) quando a energia eletromagnética incide sobre a superfície de um alvo, três tipos básicos de interações podem ocorrer: reflexão, absorção e transmissão. A proporção destes efeitos varia para diferentes feições terrestres, dependendo do tipo e condição do material, permitindo identificar diferentes características sobre uma imagem. Aplicando o princípio da conservação de energia, pode-se estabelecer uma relação entre os tipos de interações da energia, por meio da seguinte equação:

$$E_I(\lambda) = E_A(\lambda) + E_T(\lambda) + E_R(\lambda) \quad (2.2)$$

Onde $E_I(\lambda)$ representa a energia incidente sobre uma determinada feição, $E_A(\lambda)$ a energia absorvida, $E_T(\lambda)$ a energia transmitida e $E_R(\lambda)$ a energia refletida. A dependência do comprimento de onda significa que, até mesmo dentro de um determinado tipo de feição, a proporção de energia refletida, absorvida ou transmitida variará para diferentes comprimentos de onda. Assim, dois tipos de cobertura de solo podem ser indistinguíveis em um intervalo espectral e serem bem diferentes em outro comprimento de onda (LILLESAND e KIEFER, 1994).


Na transmissão, a energia atravessa o alvo (ex.: uma folha), com uma mudança na

velocidade, de acordo com o índice de refração do material. Na absorção, a energia é absorvida pelo alvo, sendo convertida em calor, e reemitida para a atmosfera; sendo captada por sensores que operam na região do IV termal (Figura 2.7). Na faixa do IV termal a energia captada pelo sensor é essencialmente emitida pelo próprio objeto, enquanto que a energia proveniente dos intervalos do visível, do IV próximo e médio é essencialmente refletida pelo objeto.

As propriedades de reflectância das feições terrestres são muito importantes, devido a muitos sistemas de sensoriamento remoto operarem nas regiões de comprimento de onda, nas quais predomina a energia refletida. A reflexão pode ocorrer na forma especular ou difusa (Figura 2.7).

A reflexão especular ocorre quando a superfície é suave (ex.: rio de águas tranquilas), onde parte da luz incidente (que não é absorvida e nem transmitida) é refletida em um ângulo igual ao de incidência, equivalendo-se a um espelho. Na reflexão difusa, parte da luz incidente, que não é absorvida e nem transmitida, é refletida em diversos ângulos e em diversas intensidades, pois para distintos corpos, energias e comprimentos de onda, têm-se diferentes intensidades refletidas e/ou emitidas.

FIGURA 2.7 – INTERAÇÕES DA ENERGIA ELETROMAGNÉTICA COM A SUPERFÍCIE TERRESTRE



FONTE: Adaptado de LILLESAND e KIEFER, 1994

Dentro da porção visível do espectro, estas variações espectrais resultam em um efeito visual chamado cor. Por exemplo, um objeto é considerado "azul" quando ele tem alta reflectância na porção azul do espectro, "verde" quando reflete muito na região verde do

espectro e assim por diante. Assim, os olhos utilizam variações espectrais na magnitude da energia refletida para distinguir entre vários objetos.

A reflectância de determinada superfície terrestre pode ser determinada pela divisão da energia refletida pela energia incidente como uma função de comprimento de onda chamada de reflectância espectral (ρ_λ), matematicamente definida como 2.3, onde ρ_λ é expressa como uma porcentagem. Portanto, a reflectância de objetos variará de acordo com suas propriedades, condições de iluminação, posição do sensor e condições atmosféricas diferentes.

$$\rho_\lambda = E_R(\lambda) / E_I(\lambda) * 100 \quad (2.3)$$

2.1.5.1. Curva de reflectância espectral

Os objetos ou materiais possuem diferentes características espectrais, podendo ser identificados por sua assinatura espectral que equivale a um valor de reflectância em uma parte específica do espectro eletromagnético. A assinatura espectral pode ser representada através de um gráfico chamado de curva de reflectância espectral, onde a reflectância pode ser expressa no intervalo de valores de 0 a 1.0 ou como uma porcentagem, relacionada com o comprimento de onda.

A configuração da curva de reflectância espectral fornece a percepção das feições de um objeto e tem uma grande influência na escolha da(s) região(s) do espectro na qual os dados de sensoriamento remoto serão adquiridos para uma aplicação específica (LILLESAND e KIEFER, 1994). Portanto, para utilizar efetivamente dados de sensoriamento remoto, deve-se conhecer e compreender o comportamento espectral das feições específicas sobre investigação em uma dada aplicação, bem como os fatores que influenciam este comportamento.

2.1.6. Sistemas Sensores

Um sistema sensor é constituído basicamente por um coletor (lente, espelho ou antena), um sistema de registro (detector, que pode ser um filme ou outro dispositivo) e um processador. A energia emitida ou refletida pelo alvo é registrada pelo sensor, resultando em imagens que correspondem a intervalos de comprimento de onda que cada sensor opera.

2.1.6.1. Classificação dos sistemas sensores

Existem muitos tipos de sensores e também muitos critérios utilizados para classificá-los. Alguns destes critérios de classificação são quanto: à fonte de energia, à região espectral, ao número de bandas espectrais, ao princípio de funcionamento e ao tipo de produto.


a) Quanto à fonte de energia

Os sistemas sensores podem ser classificados em função da fonte de energia como: passivos e ativos.

Os sensores passivos não emitem energia (Figura 2.8), mas captam a energia refletida e/ou emitida pelos alvos, que provém de uma fonte externa ou do próprio ambiente. Como exemplo tem-se: radiômetros, espectrorradiômetros e termômetros de radiação. A maioria dos sensores dos satélites de sensoriamento remoto são passivos. A principal fonte de energia disponível é a energia do Sol que incide sobre o planeta, sendo captada pelos sensores depois de haver interagido com a superfície e a atmosfera (LILLESAND e KIEFER, 1994).

Os sensores ativos (Figura 2.8) emitem energia por meio de uma fonte própria. Um exemplo muito comum é o da câmera fotográfica utilizando o *flash*, porém a mesma câmera utilizando somente a luz solar torna-se um sensor passivo (LILLESAND e KIEFER, 1994). Um outro exemplo de sensor ativo é o radar, o qual emite energia na região de microondas do espectro eletromagnético e capta a energia refletida pelos materiais que estão sobre a superfície terrestre.

FIGURA 2.8 – REPRESENTAÇÃO DE UM SENSOR PASSIVO E ATIVO



b) Quanto à região espectral

Todos os sistemas de sensoriamento remoto projetados para monitorar a superfície terrestre dependem da energia que é refletida e/ou emitida das feições desta. Os sistemas de sensoriamento remoto podem ser classificados de acordo com a região espectral na qual operam sendo denominados de: sensores de energia solar refletida ou termal quando atuam na região óptica do espectro e sensores de imageamento de radar quando operam na região das microondas.

O sensor de energia solar refletida detecta a energia que foi refletida das feições da superfície em uma ou mais regiões do espectro: ultravioleta, visível, IV próximo e IV médio. Este é o sensor mais utilizado no monitoramento de recursos terrestres.

O sensor termal detecta a radiação emitida por feições da superfície podendo revelar informações sobre as propriedades térmicas destes materiais através da região do IV termal.

O sensor de imageamento de radar não depende de uma fonte natural; estes sistemas “ativos” “iluminam” a superfície com a radiação das microondas para depois medir a energia que é refletida atrás do sensor. A energia devolvida gera informações da superfície terrestre como: estrutura, umidade e forma.

c) Quanto ao número de bandas espectrais

Os sensores podem ser classificados quanto ao número de bandas detectadas em: pancromáticos, multiespectrais e hiperespectrais.

Os sensores pancromáticos registram uma única faixa larga do espectro eletromagnético (visível a IV próximo), provendo uma avaliação resumida da cena, geralmente com uma resolução espacial (vide item 2.1.6.2.) mais alta do que outros sensores a bordo. Uma imagem pancromática revela variações espaciais nas propriedades visuais dos materiais da superfície, mas não permite a discriminação espectral. Por exemplo, o sensor do Ikonos inclui uma banda pancromática com um intervalo espectral de 0.45 a 0.90 micrômetros (azul, verde, vermelho e IV próximo). Esta banda tem uma resolução espacial de 1 metro, em contraste com a resolução espacial de 4 metros do sensor multiespectral.

Os sensores multiespectrais registram simultaneamente várias faixas largas do espectro, gerando imagens da mesma cena. Estas imagens multiespectrais ampliam a possibilidade de se extrair informações de um objeto ou de uma área na superfície, pois permitem analisar o comportamento espectral de um alvo nas distintas bandas do espectro. A maioria dos sensores multiespectrais utiliza de três a seis bandas espectrais, abrangendo a região do visível ao IV médio. Alguns sistemas também utilizam uma ou mais bandas IV termais.


As imagens multiespectrais podem ser comparadas com as imagens coloridas obtidas por uma câmera fotográfica digital. A imagem colorida é adquirida pelo sensor da câmera que registra as informações da região do verde, vermelho e azul e, ao projetar as três bandas no canhão de cores RGB, compõe-se uma imagem formada pelos elementos captados em cada uma das cores. Na realidade, uma imagem colorida (padrão RGB) é constituída de um conjunto de três imagens, obtidas por sensores em diferentes intervalos do espectro eletromagnético.

A composição RGB das imagens multiespectrais pode ser efetuada de várias formas. No caso do Ikonos, ao efetuar a combinação Vermelha (Banda 3) = R, Verde (Banda 2) = G, Azul (Banda 1) = B, simula-se a cor “natural”. Neste caso, se na cena da imagem

existirem rios ou lagos com sedimentos suspensos ou algas, estes serão apresentados em tom azul-verde. Efetuando-se a combinação IV próximo (Banda 4) = R, Vermelha (Banda 3) = G, Verde (Banda 2) = B, simulam-se as cores de uma fotografia colorida infravermelha, onde a vegetação verde saudável aparece destacada com a cor vermelha. Na Figura 2.9, são apresentadas as três bandas do visível (azul, verde e vermelho) de uma imagem do Ikonos (pequena área da cidade de Rio Negro) e a imagem colorida obtida da simulação da cor “natural” pela distribuição dessas bandas no canal RGB.

Os sensores hiperspectrais registram simultaneamente várias faixas estreitas do espectro, gerando imagens da mesma cena, ampliando ainda mais a possibilidade de se extrair informações. A maioria dos sensores hiperspectrais utiliza de dúzia a centenas de bandas espectrais.

FIGURA 2.9 – IMAGEM IKONOS: BANDAS DO VISÍVEL: AZUL, VERDE E VERMELHA E A COMPOSIÇÃO RGB



d) Classificação quanto ao princípio de funcionamento

Os sistemas sensores podem ser ainda classificados em duas categorias em função do processo utilizado na formação da imagem: de varredura (*scanning systems*) e de quadro (*framing systems*). Nos sistemas sensores de varredura a imagem da cena é formada pela aquisição seqüencial de pequenas porções da cena. Já os sistemas sensores de quadro registram a energia refletida da cena em sua totalidade em apenas uma operação (NOVO, 1993).

e) Classificação quanto ao tipo de produto

Os sistemas sensores podem ser classificados em função do tipo de produto gerado como sistemas imageadores e não-imageadores.

Os sistemas sensores imageadores fornecem como resultado uma imagem de um alvo ou região sob investigação. Alguns sensores imageadores conhecidos são: os fotográficos, de imageamento eletro-óptico e os radares de visada lateral.

Os sistemas sensores não-imageadores fornecem informações sobre o alvo sem produzir imagens. Estas informações podem ser números, gráficos, tabelas, etc. Entre estes sensores mais conhecidos encontra-se o radiômetro, cuja saída é em forma de dígitos ou gráficos.

2.1.6.2. Resolução espacial


No sentido prático, a resolução espacial descreve “o quanto” de detalhes em uma imagem é visível para o sistema visual humano. Em imagens geradas por sistemas de alta resolução (ex.: Ikonos com 4 metros) pode-se observar pequenos detalhes dos objetos, que não poderiam ser observados em imagens de baixa resolução espacial (ex.: Landsat com 30 metros).

O efeito da redução da resolução, pode ser compreendido, por meio do exemplo de uma pessoa que usa óculos: ao retirá-los a pessoa vê os objetos borrados, sem boa definição de forma e detalhes. A habilidade de discriminar pequenos detalhes é uma forma de descrever o que é chamado de resolução espacial. Portanto, quanto menor o objeto possível de ser visto com boa acuidade na imagem, melhor é a resolução espacial do sensor.

A distância entre o alvo da imagem e o sensor junto com o ângulo visto e o sistema de lente representam os itens fundamentais para determinar os detalhes das informações obtidas e o total da área visualizada pelo sensor. Em geral, a resolução espacial de um detector é expressa através das propriedades geométricas do sensor, definidas pelo campo de visada instantâneo ou IFOV (*instantaneous field of view*). O IFOV (Figura 2.10) define a área

do terreno focalizada em uma dada altitude e em um determinado instante de tempo pelo instrumento sensor. A distância sobre o terreno que corresponde a esse ângulo, considerando a altura de vôo, corresponde ao tamanho da mínima unidade de informação incluída na imagem, que se denomina de célula de resolução e determina a resolução máxima de um sensor (CHUVIECO, 1990).

FIGURA 2.10 – REPRESENTAÇÃO DO CAMPO INSTANTANEO DE VISADA (IFOV)

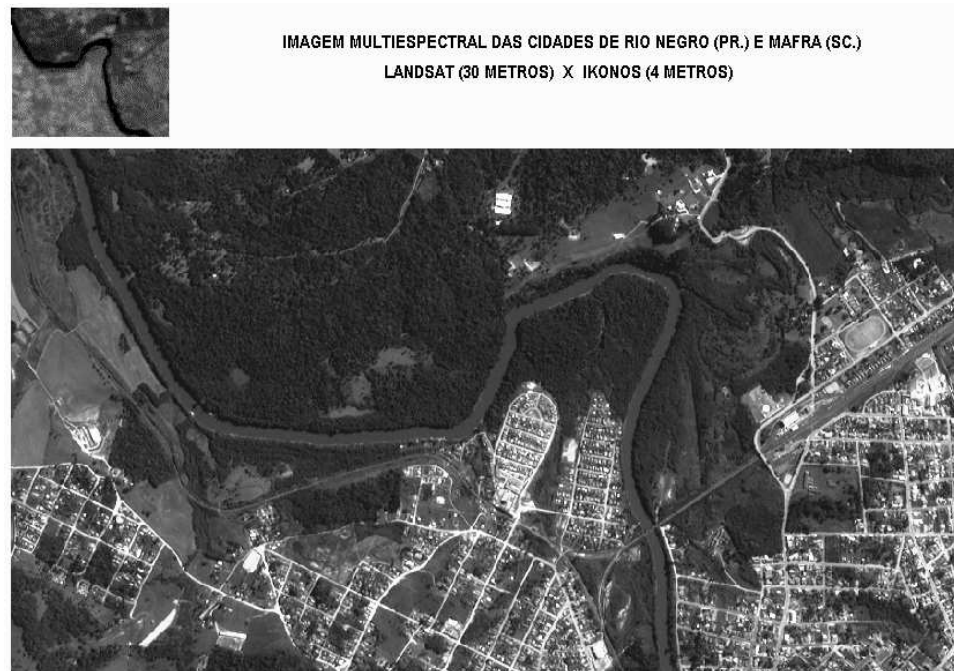


A resolução espacial de imagens adquiridas por sistemas sensores a bordo de satélites é geralmente expressa em metros. Por exemplo, a imagem multiespectral Ikonos tem uma resolução espacial de 4 m, que se mostra superior à resolução espacial do sensor Landsat que é 30 m.

Deve-se atentar para o fato de que a resolução não estabelece o tamanho do menor objeto que pode ser detectado na imagem, sendo possível ver um objeto muito menor que o definido pela resolução espacial da imagem. Por exemplo, objetos menores do que 4 m (ex.: linhas nas imagens que poderiam ser ruas, estradas, rios, etc) aparecem nas imagens multiespectrais Ikonos, embora não possam ser observados com boa definição, pois, a menos, que se tenha mais informação sobre este objeto não se pode inferir com precisão o que é realmente este objeto. Portanto, mesmo nos melhores sensores ainda existem limitações na resolução espacial.

Na Figura 2.11 são apresentadas duas imagens multiespectrais que abrangem parte das cidades de Rio Negro – PR. e Mafra – SC, sendo a imagem Landsat com resolução de 30 metros e a imagem obtida do Ikonos com resolução de 4 metros. Pela Figura 2.11, pode-se observar que na imagem do Ikonos são visualizados muitos mais detalhes.

FIGURA 2.11 – EXEMPLO DA RESOLUÇÃO ESPACIAL LANDSAT X IKONOS



2.1.6.3. Resolução espectral

Segundo CHUVIECO (1990), a resolução espectral indica o número e largura das bandas espectrais que o sensor pode discriminar. Uma alta resolução espectral é obtida quando as bandas de um sistema sensor são estreitas e/ou quando se utiliza um maior número de bandas espectrais, aumentando a capacidade do sensor em registrar pequenas variações do comportamento espectral e, conseqüentemente, melhorando a diferenciação dos vários tipos de cobertura do solo. O sistema sensor Landsat possui oito bandas espectrais, tendo, portanto, uma resolução espectral melhor do que o sistema sensor Ikonos com apenas quatro.

A escolha do número, largura e localização das bandas para o sensor está intimamente relacionada com os objetivos de sua utilização (CHUVIECO, 1990). Por

exemplo, ao considerar um sensor dedicado a fins meteorológicos, basta colocar somente uma banda do visível, visto que não existem diferenças cromáticas nas nuvens. Mas, será conveniente incluir uma ou duas bandas do termal (que permitem conhecer a temperatura destas nuvens) e outra no infravermelho-médio, onde pode-se observar o conteúdo de umidade na atmosfera.

2.1.6.4. Resolução radiométrica

A energia eletromagnética, refletida e/ou emitida pelos alvos da superfície terrestre possui valor de intensidade que difere de um alvo para outro. Entretanto, certos alvos, apesar de serem diferentes, refletem ou emitem a energia eletromagnética com valores de intensidade muito próximos entre si, tornando-se quase idênticos espectralmente. Assim, a resolução radiométrica de um sensor refere-se à capacidade que este sensor tem de poder discriminar, em determinada área, alvos com pequenas diferenças de energia refletida e/ou emitida.

No caso dos sistemas fotográficos, a resolução radiométrica do sensor é indicada pelo número de níveis de cinza retirado no filme. Nos óptico-eletrônicos, a imagem habitualmente se apresenta no formato digital, devido a uma conversão analógico-digital realizada a bordo do satélite.

Portanto, identifica-se como resolução radiométrica o número possível de valores digitais que representam os níveis de cinza utilizados para expressar os dados de uma imagem coletada pelo sensor. Quanto maior o número de valores digitais, maior será a resolução radiométrica e, conseqüentemente, maior também o tamanho do arquivo utilizado para armazenar a imagem.

A resolução radiométrica de um sistema é definida pelo número de bits (dígitos binários) que representa um valor digital (nível de cinza máximo). O número de valores de níveis de cinza possíveis é dado por: $K = 2^m$, onde m é o número de bits, sendo o tom mais escuro igual a 0 e o mais claro igual a $2^m - 1$.

Uma cena com resolução de 5 bits apresentará 32 (2^5) níveis de cinza. Uma

imagem de 1 bit por *pixel*, apresentará somente 2 variações de tonalidade (preto e branco) sendo chamada de imagem binária. O satélite Landsat tem resolução radiométrica de 8 bits (256 níveis de cinza), já o Ikonos tem resolução radiométrica de 11 bits, registrando imagens com 2048 níveis de cinza. As tonalidades mais claras sempre terão números digitais maiores, pois correspondem a uma quantidade maior de energia recebida pelo sensor.

2.1.6.5. Resolução temporal

A resolução temporal é definida de acordo com as características da plataforma na qual o sensor está colocado. No caso de sistemas sensores orbitais, a resolução temporal indica a frequência de cobertura proporcionada pelo sensor, ou seja, a periodicidade com que este adquire imagens da mesma porção da superfície terrestre.

O ritmo temporal dos sistemas espaciais varia conforme as características orbitais da plataforma (altura, velocidade, inclinação), construção do sensor e ângulo de observação e de abertura, em conformidade com os objetivos definidos para o sensor (CHUVIECO, 1990). A resolução temporal é muito importante porque permite fazer um acompanhamento dinâmico dos alvos (fluxo atmosférico, crescimento de culturas, uso do solo) sobre a superfície da Terra.

Os satélites meteorológicos fornecem uma informação frequente, pois se dedicam a observar um fenômeno efêmero, proporcionando uma imagem em um intervalo de minutos. Os satélites de recursos naturais, ao contrário, oferecem imagens em intervalo de tempo maior, girando em torno de dias. O satélite Landsat tem uma resolução temporal de 16 dias, isto é, a cada 16 dias passa sobre um mesmo ponto geográfico da Terra. A resolução temporal do Ikonos é reduzida a 1.5 dias (modo multiespectral) devido à possibilidade de inclinação dos sensores (*off-nadir*).

2.1.7. Comportamento Espectral dos Alvos Naturais

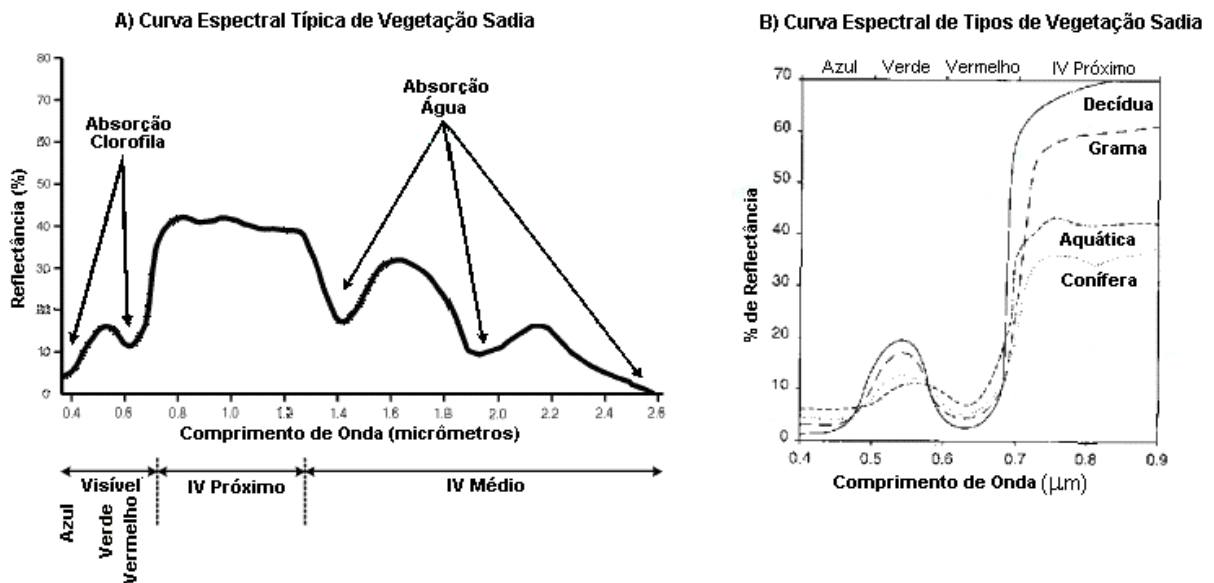
Ao analisar as reflectâncias espectrais de vegetação, terra e água, deve-se reconhecer que estes vastos tipos normalmente são espectralmente separáveis, sendo seu grau de separação variável de acordo com a região do espectro que está sendo observada. Por exemplo, água e vegetação podem refletir um comprimento de onda quase igual no visível, porém estas características quase sempre são separáveis em comprimentos de onda do infravermelho-próximo (LILLESAND e KIEFER,1994).

2.1.7.1. Vegetação

As curvas de reflectância espectral para vegetação verde saudável (Figura 2.12) quase sempre manifestam-se como uma configuração "picos e vales". Os vales na porção do visível do espectro (Figura 2.12-A) são ditados por pigmentos em folhas de plantas, como por exemplo, a clorofila, que absorve mais energia nas bandas de comprimento de onda próximo de 0.45 e 0.67 μm . Assim, os olhos percebem vegetação saudável com a cor verde por causa da absorção muito alta de energia pelas folhas da planta no azul e vermelho e a reflexão muito alta de energia no verde (pico de reflexão em 0.54 μm aproximadamente).

Na porção do espectro do visível ao infravermelho-próximo, aumenta de forma significativa a reflectância de vegetação saudável. No intervalo próximo de 0.7 a 1.3 μm , uma folha de planta reflete geralmente 40 a 50% da energia incidente, sendo a maioria da energia restante transmitida, desde que a absorção nesta região espectral seja mínima (menos que 5%). A reflectância da planta no intervalo acima citado, resulta principalmente da estrutura interna das folhas, pois esta estrutura é altamente variável entre espécies, permitindo, com frequência, discriminar entre os diversos tipos de vegetação (Figura 2.12-B). Além de 1.3 μm , a energia incidente na vegetação é essencialmente absorvida ou refletida, com pequena a nenhuma transmitância de energia.

FIGURA 2.12 – CURVAS DE REFLECTÂNCIA ESPECTRAL PARA VEGETAÇÃO SADIA




FONTE: Adaptado de LILLESAND e KIEFER, 1994

Na região do infravermelho médio ocorrem declives na reflectância a aproximadamente 1.4 , 1.9 e $2.7 \mu\text{m}$ (Figura 2.12-A) causados pela presença de água nas folhas, que absorvem mais estes comprimentos de onda. Por isso, comprimentos de onda nestas regiões espectrais são chamados faixas de absorção de água. Picos de reflectância ocorrem a aproximadamente 1.6 e $2.2 \mu\text{m}$, entre as faixas de absorção. Portanto, ao longo do intervalo acima de $1.3 \mu\text{m}$, o aumento do teor de água nas folhas acarreta uma redução de reflectância (LILLESAND e KIEFER, 1994).

A vegetação que é submetida a alguma forma de estresse (Figura 2.13) que interrompe seu crescimento normal e produtividade, pode decrementar ou cessar a produção de clorofila, resultando em menor absorção de clorofila nas bandas azul e vermelha. A reflectância no vermelho frequentemente aumenta ao ponto de se ver a planta como amarela (combinação de verde e vermelho). Estas mudanças na planta muitas vezes alteram a reflectância no intervalo de aproximadamente 0.7 a $1.3 \mu\text{m}$, e sensores que operam nesta região são freqüentemente usados para detectar estresse de vegetação.


FIGURA 2.13 – CURVAS DE REFLECTÂNCIA ESPECTRAL PARA UMA FOLHA DE PLANTA QUE PROGRIDE DE UM ESTADO SAUDÁVEL PARA DIFERENTES ESTÁGIOS DE DANO



2.1.7.2. Solo

A curvas de reflectância espectral de solo (Figura 2.14) apresentam menor variação de picos e vales. Os fatores que influenciam a sua reflectância atuam sobre faixas espectrais menos específicas. Estes fatores que afetam a reflectância do solo são complexos, variáveis e relacionados, sendo: conteúdo de umidade, textura do solo (proporção de areia, silte e argila), estrutura, presença de óxido de ferro e de matéria orgânica. A presença de umidade no solo, por exemplo, reduzirá sua reflectância, sendo este efeito maior nas faixas de absorção de água (como em vegetação) à aproximadamente 1.4, 1.9 e 2.7 μm (LILLESAND e KIEFER,1994).

FIGURA 2.14 – CURVAS DE REFLECTÂNCIA ESPECTRAL PARA SOLO



A quantidade de umidade do solo é fortemente relacionada com a sua textura: grossos, normalmente solos arenosos, são bem escoados, resultando em baixo conteúdo de

umidade e relativa alta reflectância. Já os de textura fina e pouco escoados, geralmente terão reflectância mais baixa (Figura 2.14). Na ausência de água, entretanto, o próprio solo exibirá a tendência inversa: com textura grossa, aparecerão mais escuros que com textura fina. Assim, as propriedades de reflectância do solo somente são consistentes dentro de intervalos específicos de condições. Dois outros fatores que reduzem a reflectância de solo são: a sua estrutura e o conteúdo de matéria orgânica, sendo que a presença de óxido ferroso no solo também reduz significativamente a reflectância nos comprimentos de onda visíveis.

2.1.7.3. Água


Considerando a reflectância espectral da água (Figura 2.15), provavelmente a característica mais distinta é a absorção de energia no comprimento de onda do infravermelho-próximo, quando se trata de lagos e rios ou água contendo vegetação ou terra suspensa. Devido a esta propriedade de absorção, a localização de corpos d' água com dados de sensoriamento remoto é realizada com maior facilidade em comprimentos de onda do infravermelho-próximo. As águas claras de rio absorvem relativamente pouca energia, a qual tem comprimento de onda menor que aproximadamente $0.6 \mu m$, sendo que a transmitância alta caracteriza estes comprimentos de onda com um máximo na porção azul-verde do espectro.

Na região visível do espectro as interações da energia são bastante complexas e dependem de uma série de fatores como a reflexão especular, materiais suspensos na água, fundo do corpo d'água e variáveis climatológicas. Características da água como profundidade, quantidade de materiais em suspensão (clorofila, argilas e nutrientes) e rugosidade da superfície, podem alterar o comportamento espectral da água (CHUVIECO, 1990).

Segundo LILLESAND e KIEFER (1994), nas águas turvas (por causa da presença de materiais orgânicos ou inorgânicos), a transmitância e, conseqüentemente, a reflectância alteram-se drasticamente. Por exemplo, águas que contêm grandes quantidades de sedimentos suspensos que normalmente são o resultado de erosão de solo têm reflectância mais alta no

visível que outras águas "claras" na mesma área geográfica.

FIGURA 2.15 – CURVAS DE REFLECTÂNCIA ESPECTRAL PARA ÁGUA



A reflectância de água também sofre alterações de acordo com a concentração de clorofila envolvida, pois aumentos em clorofila tendem a diminuir a reflectância de água em comprimentos de onda azul e aumentar no verde. Estas mudanças têm sido usadas para monitorar a presença e calcular a concentração de algas através de dados de sensoriamento remoto. Estes dados de reflectância também tem sido usados para determinar a presença de vários poluentes, tais como óleo e certos detritos industriais.

Muitas características importantes da água, como concentração de oxigênio dissolvido, pH e concentração de sais, não podem ser observadas diretamente por mudanças em reflectância de água, porém, tais parâmetros às vezes são correlacionados com a reflectância observada. Portanto, há muitos interrelacionamentos complexos entre a reflectância espectral de água e características específicas, devendo-se utilizar dados de referência apropriados para interpretar corretamente medidas de reflectância de modificações de água.

2.1.8. Comportamento Espectral dos Objetos Artificiais

2.1.8.1. Área urbana

O ambiente urbano destaca-se pela sua complexidade espacial e espectral, pois é composto por vários tipos de cobertura que incluem superfícies impermeáveis diversas (como estradas e edificações), vegetação, água, solo exposto, dentre outras. A estrutura tridimensional de materiais artificiais como telhados (cerâmica, barro, concreto; abrangendo cores diferentes) e outros tipos de cobertura geram uma heterogeneidade espacial e espectral muito superior a ambientes naturais, tornando a análise de imagem de sensoriamento remoto urbana um processo desafiador.

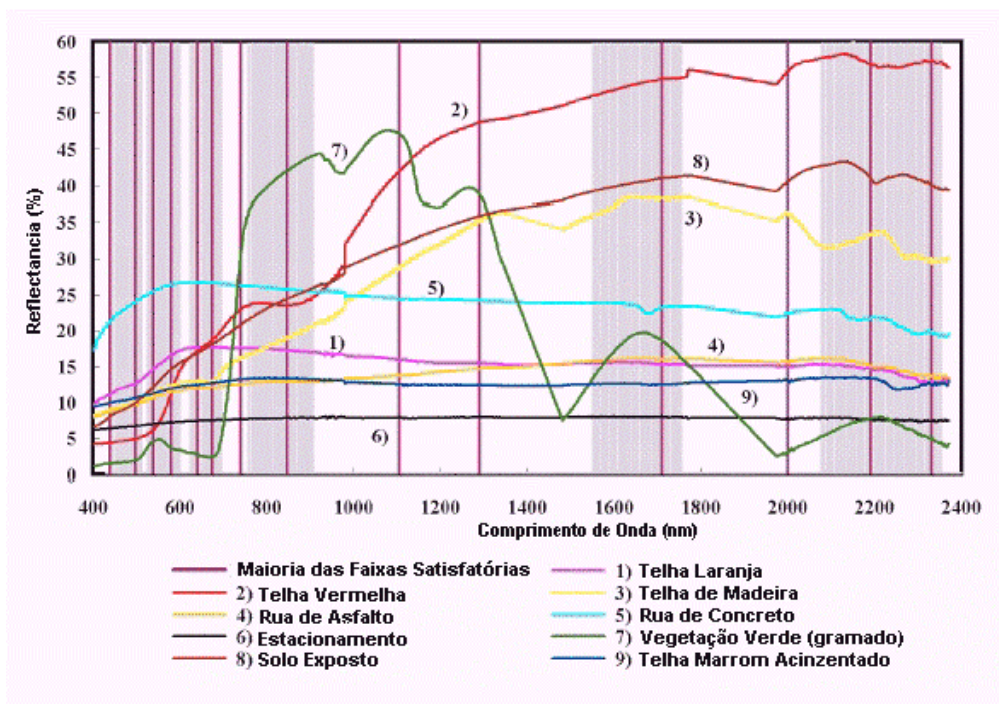
A estrutura e geometria de objetos da superfície terrestre normalmente não alteram as propriedades espectrais gerais do material da superfície, entretanto, estão sujeitas a um impacto significativo no sinal, devido a efeitos de iluminação.

A geometria do objeto relaciona forma e orientação. Em um telhado, por exemplo, conforme a posição do sol (considerando-se ângulo de declive e orientação), partes de telhados poderiam estar sendo iluminadas enquanto outras partes estariam na sombra.

As estruturas da superfície das telhas ou estrada também afetam o sinal espectral, porém em menor escala. As estradas podem ser cobertas ou sombreadas ao redor por superfícies como árvores, edifícios ou automóveis, resultando em uma resposta espectralmente distinta com uma quantidade alta de variabilidade espacial. Dentro de áreas urbanas onde a rede de estrada é particularmente densa, o efeito das sombras torna-se mais complexo.

A Figura 2.16 apresenta a curva espectral típica de elementos que compõem grande parte das áreas edificadas pelo homem, como estradas e telhados. As faixas cinza determinam os intervalos obtidos pelo sensor do Landsat TM e os quatro primeiros intervalos determinam as faixas captadas pelo sensor do Ikonos, demonstrando que este possui uma resolução espectral menor gerando limitações espectrais na identificação da cobertura terrestre.

FIGURA 2.16 – CURVAS DE REFLECTÂNCIA PARA ÁREA URBANA



Com relação aos tipos de ruas (4, 5 e 6) apresentados na Figura 2.16, as ruas de concreto (5) têm a mais alta reflectância e os estacionamentos (6) têm a mais baixa reflectância considerando todo o intervalo espectral. Lembrando que em ruas de áreas urbanas são encontradas principalmente estradas de concreto ou asfalto, mas, muitas vezes, existem diversas ruas de terra, dificultando sua identificação.

Na Figura 2.16, a telha vermelha (2) e madeira (3) mostram assinaturas espectrais distintas comparadas aos outros materiais, tendo aumento significativo de reflectância na região do IV próximo. As telhas cinza (9) apresentam reflectância relativamente constante no intervalo espectral, possuindo uma assinatura espectral semelhante a ruas de asfalto, devido ao fato que estes são compostos de materiais geralmente semelhantes, dificultando a separabilidade espectral.

A confusão espectral gerada devido aos materiais utilizados em áreas urbanas (telhados e ruas) serem semelhantes, muitas vezes é responsável pelos erros em classificações de cobertura de solo.

2.1.9. Fatores que Interferem no Comportamento Espectral dos Objetos da Superfície

Os efeitos temporais e espaciais normalmente afetam a análise de propriedades de reflectância espectrais de recursos terrestres. Os efeitos temporais são qualquer fator que altera as características espectrais de uma feição com o passar do tempo (ex.: mudanças de estações do ano e ambiente: chuvas, secas; efeitos causados pelo homem: queimadas, desmatamento; entre outros) e os efeitos espaciais podem ser observados quando em um determinado intervalo do tempo tem-se feições diferentes em locais geográficos diferentes, como por exemplo, plantação de milho.

Entretanto, efeitos temporais e espaciais podem ser a chave para obter a informação desejada em uma análise. Como por exemplo, no processo de "detecção de mudança", utilizado para medir efeitos temporais, poderiam ser detectadas as alterações no desenvolvimento suburbano próximo de uma área metropolitana, utilizando dados obtidos em duas datas diferentes. Um exemplo de um efeito espacial útil é a mudança na morfologia de folha de árvores quando elas são sujeitas a alguma forma de estresse. No caso de uma determinada árvore ser infectada por uma praga, suas folhas poderiam começar a mudar a forma e enrolar-se, alterando a reflectância da árvore se comparada com árvores saudáveis que a cercam. Assim, embora um efeito de espaço pudesse causar diferenças na reflectância espectral do mesmo tipo de característica, este efeito pode ser importante em uma determinada aplicação.

2.1.10. Satélite de Alta Resolução Ikonos

O programa Ikonos foi pioneiro no desenvolvimento de satélites comerciais de alta resolução, sendo uma iniciativa da empresa americana *Space Imaging*. O primeiro satélite da série, o Ikonos I, foi lançado em 27 de Abril de 1999, da base de Vandenberg, da Força Aérea norte-americana, porém o foguete não alcançou velocidade suficiente para que o satélite atingisse a órbita programada e caiu no Oceano Pacífico. O segundo satélite do programa, o Ikonos II, foi lançado com sucesso em 24 de setembro de 1999. Assim, o Ikonos II se tornou o

primeiro satélite comercial de alta resolução com capacidade de obter imagens de um metro de resolução espacial (SPACE IMAGING, 2002). A Tabela 2.1 apresenta um resumo das principais características do satélite Ikonos II.

TABELA 2.1 – CARACTERÍSTICAS DOS SATÉLITES Ikonos

Características do Satélite Ikonos	
Data de lançamento	24 de Setembro de 1999
Veículo de lançamento	Athena II
Local de lançamento	Base Vandenberg da Força Aérea Americana, Califórnia
Capacidade de armazenamento de dados	64 Gb
Altitude da órbita	681 km
Inclinação da órbita	98,1°
Tipo de Órbita	Sol Síncrona
Velocidade	7 km/s
Sentido da Órbita	Descendente
Horário de passagem	10:30 am
Duração da órbita	98 min
Capacidade de envio de dados	320 Mbps
Peso	725 kg
Tempo de vida útil	7 anos (máximo)
Resolução temporal	1.5 dias (modo multiespectral) 2.9 dias (modo pancromático)
Largura do imageamento	11 km (<i>nadir</i> ¹)
Imageamento	13km na vertical (cenas de 13km x 13km)
Capacidade de aquisição de imagens	Faixas de 11km x 100km até 11km x 1000km
Resolução radiométrica	11 bits (2048 níveis)
Resolução espacial	Pancromática: 1 metro Multiespectral: 4 metros
Nº de Banda	Banda Espectral
1 (Azul)	0.45 - 0.52 µm
2 (Verde)	0.52 - 0.60 µm
3 (Vermelho)	0.63 - 0.69 µm
4 (Infravermelho Próximo)	0.76 - 0.90 µm
5 (Pancromática)	0.45 - 0.90 µm

FONTE: SPACE IMAGING, 2002

¹ *nadir*: área da superfície terrestre perpendicular ao sensor. O sensor do Ikonos tem a capacidade de coletar imagens no *off-nadir*, através da visada inclinada

2.2. PROCESSAMENTO DIGITAL DE IMAGENS

2.2.1. Definição

O processamento digital de imagens envolve o desenvolvimento e uso de equipamentos, técnicas e algoritmos com a finalidade de melhorar ou modificar o aspecto visual das imagens ou de interpretar o conteúdo dessas imagens através de máquinas (GONZALEZ E WOODS, 2000). No sensoriamento remoto a identificação e distribuição dos objetos ou materiais é feita pelas suas diversas características espectrais expressas nas várias bandas de um sensor. Assim, quanto maior o número de imagens e bandas, maior será o volume de dados (LILLESAND E KIEFER, 1994).

2.2.2. Representações Gráficas

2.2.2.1. Histograma

O histograma é uma das formas mais comuns de se representar a distribuição de valores de *pixel* de uma imagem (CRÓSTA, 1992). O histograma é uma função discreta representada por (GONZALEZ E WOODS, 2000):

$$p_r(r_k) = \frac{n_k}{n} \quad (2.4)$$

onde:

r_k = k-ésimo nível de cinza


n_k = número de *pixels* na imagem cujo nível de cinza corresponde a r_k

n = número total de *pixels* na imagem

$k = 0, 1, 2, \dots, L-1$, onde L é o número de valores de *pixel* da imagem digitalizada.

Ao se observar o histograma de uma imagem, tem-se uma noção instantânea sobre as características da mesma. A forma do histograma prove informações de grande importância no caso das imagens de sensoriamento remoto, tais como intensidade média e distribuição dos valores de *pixel*. Quanto maior a distribuição ao longo do eixo dos valores de *pixel* maior o contraste da imagem (CRÓSTA, 1992). A Figura 2.17 mostra os histogramas de quatro tipos básicos de imagem (GONZALEZ E WOODS, 2000). Nas Figuras 2.17(A), 2.17(B) e 2.17(C) a maioria dos *pixels* está concentrada em uma estreita faixa da escala de cinza, significando que as imagens correspondentes apresentam baixo contraste. Porém, a Figura 2.17(D) mostra um histograma com distribuição significativa, correspondendo a uma imagem com alto contraste.

FIGURA 2.17 – EXEMPLOS DE HISTOGRAMAS

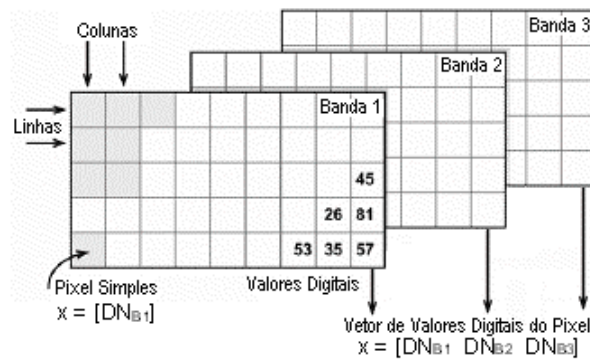


FONTE: Adaptado de GONZALEZ E WOODS, 2000

2.2.2.2. Vetor de atributos

O *pixel* da imagem multiespectral pode ser representado por um vetor que contempla os valores digitais de cada banda (RICHARDS E JIA, 1999), conforme apresentado na Figura 2.18.

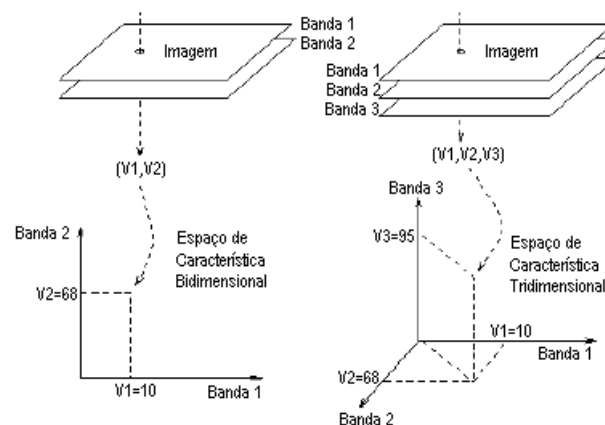
FIGURA 2.18 – REPRESENTAÇÃO DE UM VETOR DE ATRIBUTOS



2.2.2.3. Espaço de atributos

Uma forma utilizada para representar a relação entre bandas é o gráfico chamado de espaço de atributos (*feature space*), sendo possível através dele visualizar a distribuição dos valores de *pixels* de cada banda (Figura 2.19). Neste gráfico, cada banda é plotada em um eixo de coordenada gerando um hipotético “espaço espectral”. No exemplo, os valores dos *pixels* da banda 1 são representados no eixo x, os valores dos *pixels* da banda 2 no eixo y e os valores dos *pixels* da banda 3 no eixo z. Neste exemplo são apresentados espaços de atributo bidimensional e tridimensional. No caso bidimensional, dois valores digitais bidimensionais, ou vetores de atributos, são atribuídos para cada *pixel*. Estes dois números digitais localizam cada *pixel* no “espaço de atributos” bidimensional do gráfico. Assim, se na banda 1 o valor do *pixel* é 10 e na banda 2 o valor para o mesmo *pixel* é 68, o vetor de atributo para este *pixel* será representado por um ponto nas coordenadas (10,68) no espaço de atributos. No espaço de atributos tridimensional o mesmo ponto será representado nas coordenadas (10,68,95).

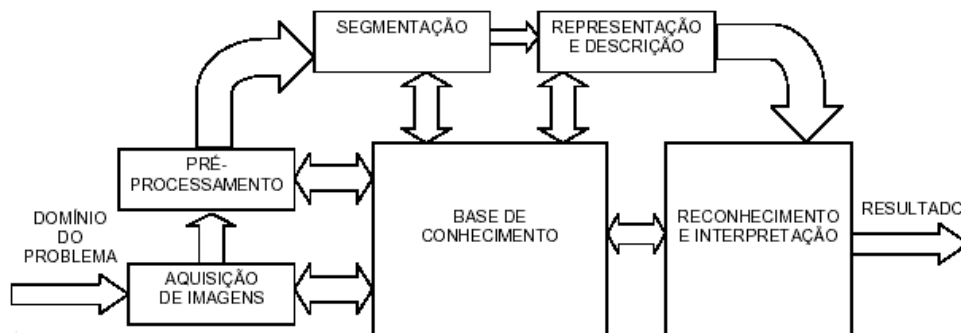
FIGURA 2.19 – ESPAÇO DE ATRIBUTOS



2.2.3. Etapas

Segundo GONZALEZ E WOODS (2000), as etapas fundamentais de um sistema de processamento de imagens (Figura 2.20) podem ser definidas de acordo com os seguintes passos: domínio do problema, aquisição da imagem, pré-processamento, segmentação, representação e descrição, reconhecimento e interpretação e o resultado. Durante o processamento da imagem, uma base de dados recebe as informações relevantes que foram extraídas da imagem, podendo ser consultada a qualquer momento.

FIGURA 2.20 – PASSOS FUNDAMENTAIS EM PROCESSAMENTO DE IMAGENS DIGITAIS



FONTE: GONZALEZ E WOODS, 2000

As etapas de processamento de imagens são muitas, mas nem sempre nas aplicações todas essas etapas são necessárias. Alguns autores clássicos de sensoriamento remoto, como LILLESAND e KIEFER (1994) definem os estágios de processamento de imagens de forma simplificada, conforme apresentado na Figura 2.21.

FIGURA 2.21 – ETAPAS DO PROCESSAMENTO DE IMAGENS DIGITAIS EM SENSORIAMENTO REMOTO



Ambas as figuras (2.20 e 2.21) demonstram que o objetivo global é produzir um resultado a partir do domínio do problema por meio de processamento de imagens. Como o foco deste trabalho é o processamento de imagens de satélite serão explanadas as etapas de

processamento de acordo com a Figura 2.21.

De acordo com a Figura 2.21, inicialmente deve ser especificado o domínio do problema, ou seja, que tipo de informação espera-se obter com o sistema, como por exemplo, uma aplicação em hidrografia. Depois, procede-se a aquisição da imagem, isto é, adquirir uma imagem digital. Neste caso, a aquisição das imagens é feita via satélite de observação terrestre, que fornece imagens diretamente em formato digital, eliminando-se a fase de digitalização, pois os sensores para imageamento têm a capacidade de digitalizar o sinal produzido. Após a obtenção de uma imagem digital, o próximo passo trata de pré-processar a imagem, isto é, corrigir distorções ou degradações da imagem que foram originadas no processo de aquisição, gerando uma representação mais fiel da cena original. No exemplo, poderiam utilizar-se técnicas para corrigir os efeitos atmosféricos inseridos na imagem. Na etapa de realce utilizam-se técnicas para facilitar a interpretação visual de uma imagem aumentando a distinção aparente entre as características na cena. No exemplo, é possível realçar características aumentando-se o contraste da imagem. No passo de classificação são utilizadas técnicas de forma a obter informações específicas, como a detecção de objetos na cena. No exemplo, existe a possibilidade de ser utilizado o método de classificação da máxima verossimilhança a fim de detectar rios. Neste caso, o resultado seria um mapa dos cursos d'água com as suas características.

A seguir são descritos os estágios de processamento abordando de forma mais detalhada as técnicas que possuem relevância na abordagem apresentada neste trabalho.

2.2.4. Pré-Processamento

As operações de pré-processamento são frequentemente chamadas de procedimentos de retificação e restauração de imagens, porque normalmente precedem a manipulação e análise dos dados da imagem para extrair informações específicas. Estas técnicas tem como objetivo corrigir distorções ou degradações da imagem que foram originadas no processo de aquisição da imagem, de forma a gerar uma representação mais

fidedigna da cena original. Assim, a natureza de qualquer processo de restauração varia com tais fatores como o tipo de aquisição da imagem digital (câmera digital ou *scanner*), plataforma (avião ou satélite) e o campo de visão total. Os procedimentos mais utilizados são: correções geométricas, correções radiométricas e remoção de ruídos (LILLESAND e KIEFER, 1994).

2.2.4.1. Correção radiométrica

A correção radiométrica é um termo genérico que designa as técnicas que modificam os níveis de cinza originais de forma a corrigir distorções de valores (CHUVIECO, 1990). Dentro deste conceito são englobadas as distorções provocadas pelas condições atmosféricas, variações na zona de iluminação ou geometria da visão, bem como erros radiométricos ocorridos devido a defeitos no funcionamento do sensor (LILLESAND E KIEFER, 1994).

No caso de erro ocasionado pela atmosfera, pode ser efetuada a correção atmosférica. A correção atmosférica tem o objetivo de reduzir os efeitos resultantes da interferência atmosférica sobre os valores de *pixel* registrados. A técnica de correção mais elementar baseia-se na suposição de que o efeito atmosférico é aditivo. Determina-se para cada banda individualmente, um valor de *pixel* que representa o efeito de espalhamento, este valor constante é utilizado na operação de subtração de cada *pixel* da imagem, alterando o valor do mesmo.

Os erros radiométricos gerados devido a diversos fatores, com exceção das condições atmosféricas podem gerar imagens com ruído, isto é, imagens com respostas espectrais indesejadas, impactando na qualidade da cena. Algumas das técnicas utilizadas na correção radiométrica, de forma a minimizar as diferenças entre os níveis de cinza registrados são: os filtros verticais, os filtros passa-baixa e o ajuste do histograma. Mais detalhes sobre correção radiométrica podem ser encontrados em LILLESAND e KIEFER (1994), CHUVIECO (1990), NOVO(1993).

2.2.5. Realce

O objetivo do realce é melhorar a interpretação visual de uma imagem aumentando a distinção aparente entre as características da cena (LILLESAND e KIEFER, 1994). Não existe nenhuma regra para produzir a "melhor" imagem, pois a técnica a ser utilizada depende da aplicação específica e, muito freqüentemente, várias melhorias são necessárias na imagem original. A maioria das técnicas de realce podem ser classificadas em operações pontuais ou locais. Operações pontuais modificam o valor de cada *pixel* independentemente do conjunto da imagem e, operações locais modificam o valor de cada *pixel* baseado nos valores de seus vizinhos. Qualquer forma de realce pode ser executada em apenas uma banda ou em várias bandas da imagem (JENSEN, 1996).

Segundo LILLESAND e KIEFER (1994), as técnicas de realce podem ser classificadas em: manipulação do contraste, manipulação de características espaciais e manipulação multi-imagens. Estas técnicas serão descritas nos itens a seguir.

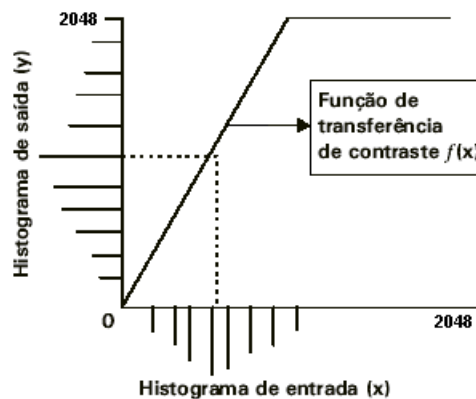
2.2.5.1. Manipulação de contraste

Eventualmente, a imagem adquirida poderá apresentar-se bastante clara (maioria dos *pixels* próximos ao número máximo de valores) ou escura (maioria dos *pixels* concentrados em valores próximos a zero). Isto pode ocorrer devido a danos no sensor, iluminação inadequada ou até mesmo às características próprias dos objetos que compõem a cena. A função de aumento de contraste procura redistribuir os valores de *pixel* de forma a ocupar toda a escala de valores digitais possíveis em determinada imagem. É uma maneira bastante eficaz, entre outras, de se realçar as feições (alvos) de uma imagem, melhorando a qualidade visual dela, sem, no entanto, alterar a quantidade de informação inicial.

Na visualização de um histograma, é possível descrever a distribuição estatística dos *pixels* de uma imagem, isto é, conhecer o número de *pixels* para cada um dos valores digitais (SCHOWENGERDT,1983). É necessário ressaltar que um histograma não fornece informações sobre a distribuição espacial dos *pixels* na imagem, porém, é possível fazer uma

inferência observando a distribuição de *pixels* no histograma, em função dos valores digitais dos alvos. Através da análise do histograma, caso necessário, poderá ser modificada a distribuição dos *pixels*, optando por uma função de transferência de contraste (Figura 2.22), definida por $y=f(x)$. Essa operação consiste em associar o valor digital mínimo e máximo da imagem analisada aos valores mínimo e máximo possíveis no histograma, obtendo, assim, maior contraste entre as classes de informações. Entre as funções existentes, a ampliação linear de contraste é a mais simples e utilizada, cuja função de transferência é uma reta. Nesta, os valores digitais da cena são escalonados linearmente, resultando em uma nova distribuição para os *pixels*. Conforme Figura 2.22, os valores digitais mínimo e máximo da imagem original assumem, respectivamente, os valores 0 a 2048 na imagem transformada. Os valores intermediários da imagem original são redistribuídos proporcionalmente, segundo a função $f(x)$. Além do modelo linear, a ampliação de contraste pode seguir o modelo gaussiano (normal), equalizado, entre outros.

FIGURA 2.22 – EXEMPLO DE UM AUMENTO LINEAR DE CONTRASTE DA IMAGEM



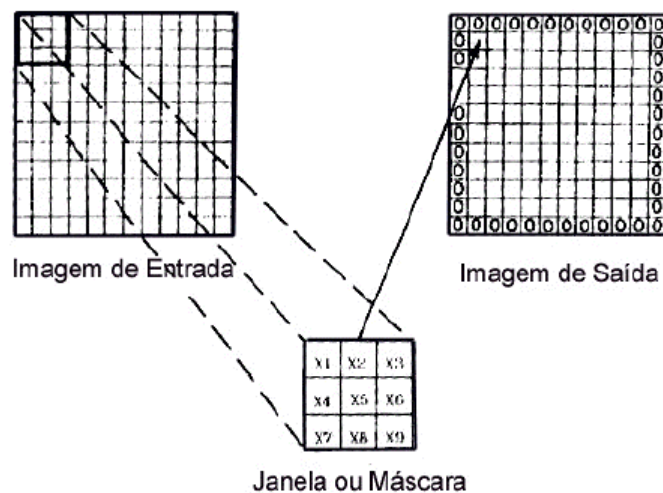
FONTE: CRÓSTA, 1993

2.2.5.2. Manipulação de características espaciais

A manipulação de características espaciais consiste na transformação dos valores de *pixel* de uma imagem, considerando a vizinhança na qual o *pixel* está inserido (LILLESAND e KIEFER, 1994). Este procedimento é efetuado através do método chamado

filtragem espacial. Neste método são utilizados algoritmos que utilizam o deslocamento de uma máscara ou janela de dimensões ímpares (3X3, 5X5, etc.). Essas janelas possuem valores diferentes para cada componente, os quais variam em função do filtro aplicado. O procedimento de filtragem consiste em se deslocar esta janela sobre a imagem, *pixel a pixel*, aplicando um cálculo matemático que utiliza os números digitais de todos os *pixels* sob a janela e os valores contidos na janela, substituindo o *pixel* central da imagem original com o novo valor calculado (CRÓSTA, 1993). Esse procedimento é exemplificado na Figura 2.23.

FIGURA 2.23 – EXEMPLO DA JANELA MÓVEL PARA FILTRAGEM DE UMA IMAGEM POR CONVOLUÇÃO



FONTE: CRÓSTA, 1993

Alguns dos filtros utilizados são:

a) Filtros “passa-baixa”: recebem esta denominação os filtros que deixam passar apenas as baixas frequências, ou seja, eliminam grandes contrastes como, por exemplo, bordas bem definidas. São chamados também de filtros de suavização devido ao efeito que causam na imagem original após a sua aplicação;

b) Filtros “passa-alta”: esses filtros deixam passar apenas as altas frequências espaciais. São chamados filtros de realce de bordas, pois ressaltam mudanças bruscas nos níveis de cinza, que caracterizam bordas;

c) Filtros direcionais: são filtros passa-alta que realçam determinada direção;

d) Filtros de convolução: são filtros destinados à eliminação de ruído nas imagens digitais.

2.2.5.3. Manipulação multi-imagens

A manipulação multi-imagens pode envolver transformações de imagens: multiespectrais, multi-sensores ou multitemporais. Nas imagens multiespectrais a operação pode ser efetuada pela utilização das várias bandas espectrais de uma mesma cena, em multi-sensores são utilizadas imagens obtidas por diferentes sensores e em multitemporais são utilizadas duas ou mais imagens da mesma área adquirida em diferentes datas (LILLESAND e KIEFER, 1994).

A execução destas transformações geram “novas” imagens de duas ou mais origens que destacam características específicas ou propriedades de interesse, melhorando as imagens de entrada originais. A manipulação multi-imagens abrange técnicas como: análise por componentes principais, transformação HSI, operações aritméticas, dentre outras. Neste trabalho serão abordadas as operações aritméticas, pelo fato das mesmas terem sido utilizadas no experimento.

Várias operações matemáticas simples são usadas em processamento digital de imagens de sensoriamento remoto, com o intuito de analisar imagens multiespectrais e/ou multitemporais. A entrada deste tipo de operação pode ser uma ou mais imagens e a saída corresponde a uma única imagem que representa o resultado da combinação das imagens originais de acordo com alguma operação realizada *pixel a pixel* (LILLESAND e KIEFER, 1994). Alguns exemplos de operações aritméticas com imagens são: adição, subtração, multiplicação e divisão, sendo esta última também conhecida por razão de bandas (CRÓSTA, 1992).

Em geral, operadores de adição e multiplicação tendem a realçar informações correlacionadas entre bandas, enquanto que, operadores de subtração e divisão tendem a realçar informações não correlacionadas entre bandas. A subtração de imagens é


frequentemente utilizada para identificar mudanças que tenham ocorrido entre imagens coletadas em diferentes datas, sendo úteis, por exemplo, para mapear mudanças no desenvolvimento urbano ao redor das cidades e para identificar áreas onde o desmatamento está ocorrendo. Razão de bandas é a operação aritmética mais utilizada, sendo que a mesma será detalhada a seguir.

Razão de bandas tende a enfatizar e realçar variações sutis nas respostas espectrais de várias superfícies de cobertura. Imagens razão (*ratio images*) são realces que resultam da divisão do valor do *pixel* em uma banda espectral pelo seu valor correspondente em outra banda. Ela é uma operação não-linear e produz resultados que necessitam ser redistribuídos para o intervalo de valores de *pixel* antes de serem apresentados na tela. Quando o valor do denominador da divisão é maior do que o numerador, o resultado é menor do que 1, gerando um resultado que será representado por um *pixel* escuro. Ao contrário, quando o numerador for maior do que o denominador, a divisão será maior do que 1, gerando um *pixel* claro no resultado. Quando os valores do denominador e do numerador forem os mesmos, não há diferença entre as duas bandas para aquele *pixel* (CRÓSTA, 1992).

Uma das vantagens da utilização de razão de bandas é a redução das diferenças em iluminação (efeitos de sombras). As sombras podem ser geradas por características topográficas, nuvens ou por pequenos objetos como árvores ou plantações, acarretando a redução nos valores de *pixels* medidos em todos os comprimentos de onda (LILLESAND e KIEFER, 1994). Outra vantagem da razão é destacar as diferenças em reflectância espectral. Neste caso, bandas são escolhidas para acentuar a ocorrência de um material específico. Escolhe-se uma banda de comprimento de onda na qual o material é altamente refletivo (aparece claro) e outra na qual o material é fortemente absorvido (aparece escuro). Normalmente a banda mais refletiva é usada como numerador da divisão, de forma que ocorrências do material designado gerem valores mais altos, aparecendo claro na imagem razão. Como desvantagem, a operação de razão acarreta perda da informação contida nos valores absolutos de reflectância, especialmente na refletividade global, podendo também ampliar o ruído da imagem.

O problema das variações nas condições de iluminação da cena é ilustrado na Figura 2.24, que representa dois diferentes tipos de cobertura de solo: árvores que possuem folhas perenes e árvores que possuem folhas decíduas, tendo ambos os tipos de vegetação uma parte sendo iluminada pelo sol e outra parte em região de sombra. Os níveis de cinza observados para cada tipo de cobertura são mais baixos na área sombreada que na área iluminada pelo sol. Entretanto, ao fazer a razão das bandas A e B, os valores resultantes para cada tipo de cobertura são aproximadamente idênticos (Tabela 2.2). Pois, independente da condição de iluminação, dois objetos que possuem a mesma propriedade de reflectância, apresentam o mesmo valor de *pixel*, apesar de estarem em diferentes posições em relação a orientação do Sol (LILLESAND e KIEFER, 1994).

FIGURA 2.24 – EXEMPLO DAS CONDIÇÕES DE ILUMINAÇÃO DE UMA CENA



FONTE: Adaptado de: LILLESAND e KIEFER, 1994

TABELA 2.2 - REDUÇÃO DA ILUMINAÇÃO DE CENA EFETUADA POR RAZÃO ESPECTRAL

Cobertura de solo/ Iluminação	Valor <i>Pixel</i> Banda A	Valor <i>Pixel</i> Banda B	Divisão (Banda A/Banda B)
Folha Decídua			
Ensolarada	48	50	0.96
Sombreada	18	19	0.95
Folha Perene			
Ensolarada	31	45	0.69
Sombreada	11	16	0.69

FONTE: Adaptado de: LILLESAND e KIEFER, 1994

Existem diversas combinações de razões que podem ser calculadas. O número de possíveis combinações que podem ser desenvolvidas de n bandas de dados é dado por $n(n-1)$.

Assim, para dados do IKONOS, por exemplo, podem-se ter até 12 diferentes relações de combinação.

A razão de bandas tem sido extensivamente utilizada no mapeamento da condição de vegetação. Estas combinações matemáticas de duas ou mais bandas são chamadas de índices de vegetação. Estes índices são desenvolvidos a partir de medidas das bandas do vermelho (ou visível) e infravermelho próximo e estão baseados em conceitos físicos simples: plantas refletem menos luz no visível, mas mais energia no infravermelho próximo, comparadas com superfícies de não-vegetação. Uma razão da banda infravermelha próximo e vermelha (Banda 4 / Banda 3, no IKONOS) é útil para mapear vegetação e condições de vegetação. A razão é alta para vegetação saudável, mas menor para vegetação estressada ou amarela (valores baixos no infravermelho próximo e alto no vermelho) e para áreas de não vegetação. Apesar de existir uma grande variedade de índices, o mais utilizado é o NDVI (*Normalized Difference Vegetation Index*) (LILLESAND E KIEFER, 1994). O NDVI, isto é, índice normalizado da diferença de vegetação é descrito pela seguinte fórmula:

$$NDVI = \frac{IV \text{ Pr óximo} - Vermelho}{IV \text{ Pr óximo} + Vermelho} \quad (2.5)$$

Como o nome indica, este índice é normalizado, gerando valores entre -1 e 1. A saída para vegetação verde saudável é relativamente alta (próxima de 1), sendo estas áreas apresentadas em níveis de cinza mais claros. Porém, a superfície terrestre coberta por vegetação, nem sempre abrangerá apenas vegetação verde saudável. Desta forma, áreas que possuem vegetação seca ou enferma, gerarão resultados bem menores do que 1, influenciando na resposta espectral do local analisado (LILLESAND E KIEFER, 1994). Alguns autores sugerem que uma superfície coberta por vegetação corresponde a $NDVI > 0.1$ e que vegetação densa corresponde a $NDVI > 0.5$ (CHUVIECO, 1990).

Muitas pesquisas têm sido realizadas em relação a geração de novos índices, dentre estas, pode-se destacar o estudo efetuado por POLIDÓRIO et al. (2003), o qual propõe um índice que busca classificar os objetos de uma imagem em duas classes: a artificial

(construções feitas pelos homens) e a natural (vegetação, sombra, solo exposto, etc.). Considerando que se tem como objetivo separar objetos artificiais dos naturais pode-se observar através das decomposições das bandas do visível (azul, verde e vermelha), que a variação do atributo intensidade de feições naturais (sombras e solo exposto) nestas bandas é muito sutil. A vegetação tem uma boa contribuição na banda verde, mas sofre pouca alteração nas bandas vermelha e azul e as edificações sofrem uma variação maior de uma banda para outra. Neste índice procura-se obter o grau de artificialidade das feições da cena através de uma operação chamada *NandA (Natural and Artificial)*, que utiliza a seguinte equação:

$$NandA = Verde - (Vermelho + Azul) \quad (2.6)$$

A aplicação da fórmula acima irá realçar as edificações, deixando-as em tons mais escuros, enquanto que a vegetação ficará em tons mais claros, facilitando o processo de classificação e separação destas feições. Quanto ao solo exposto, a tonalidade resultante depende do seu tipo. Em geral, ele fica com uma tonalidade constante intermediária entre o da vegetação e o das edificações o que, dependendo da situação, pode provocar confusão no processo de classificação.

2.2.6. Classificação

O objetivo da classificação de imagens em sensoriamento remoto é identificar as feições na imagem, isto é, traduzir os diversos padrões de energia eletromagnética refletida em classes de cobertura terrestre (LILLESAND e KIEFER, 1994). Estas classes temáticas de cobertura terrestre podem incluir: tipos de floresta como: floresta perene e decídua; tipos de uso de terra agrícolas como: gramado e plantação; tipos de cobertura de solo urbano como: áreas residenciais e parques industriais e; mais genericamente classes de cobertura terrestres tais como água, solo exposto, etc. A base conceitual para classificação de imagem é que classes de cobertura terrestre diferentes têm propriedades de reflectância diferentes. Porém,

muitas classes de cobertura terrestre possuem propriedades de reflectância que se assemelham ou se sobrepõem, dificultando a separação das mesmas. A maioria dos métodos de classificação avaliam a semelhança de padrões espectrais usando alguma medida da distância entre *pixels* do espaço espectral.

As técnicas de classificação que podem ser aplicadas somente a um canal espectral (banda da imagem) são conhecidas como classificações unidimensionais. As técnicas em que o critério de decisão depende da distribuição de valores de *pixel*, em várias bandas espectrais, são definidas como técnicas de classificação multiespectral (NOVO, 1993), sendo este o método mais freqüentemente utilizado na extração de informações de imagens de sensoriamento remoto (RICHARDS e JIA, 1999).

Na classificação multiespectral, os vetores de valores digitais para cada *pixel* são "comparados", e os *pixels* com valores mais similares segundo uma regra de decisão (NOVO, 1993), tendem a ser associados a um "rótulo" chamado de classe. O resultado final de um processo de classificação é uma imagem digital que constitui um mapa de *pixels* classificados, representados por símbolos gráficos ou cores chamado imagem classificada (CRÓSTA, 1992). Cada *pixel* da imagem original é classificado dentro de uma das diversas classes, mostrando a distribuição geográfica de um tema, tal como vegetação ou solo. A fase de atribuição dos *pixels* a determinada classe é de grande importância e complexidade no processo classificatório, sendo que, atualmente a maioria dos sistemas de decisão utilizam conceitos de estatística. As técnicas de classificação podem ser divididas em: classificação supervisionada e classificação não supervisionada.

2.2.6.1. Classificação Supervisionada

A classificação supervisionada é o procedimento utilizado com maior frequência para análise quantitativa de dados de imagens de sensoriamento remoto. Neste processo são utilizados algoritmos para nomear os *pixels* em uma imagem de forma a representar tipos específicos de cobertura terrestre, ou classes que são conhecidas *a priori* (RICHARDS e JIA,

1999; LILLESAND e KIEFER, 1994).

Segundo RICHARDS e JIA (1999), uma variedade de algoritmos está disponível para classificação supervisionada (Figura 2.25), entretanto, independente do método escolhido, os passos práticos essenciais são:

a) Decidir o conjunto de tipos de cobertura de solo ou classes de informação (área urbana, água, etc), dentro dos quais a imagem deverá ser classificada.

b) Escolher *pixels* representativos de cada classe desejada, sendo estes *pixels* chamados de dados de treinamento (NOVO, 1993). Os conjuntos de treinamento de cada classe podem ser estabelecidos utilizando visitas a campo, análise de mapas, fotografias aéreas ou até mesmo foto interpretação de um produto colorido formado por dados da imagem (em forma de cópia ou exibição colorida) (JENSEN, 1996). Os *pixels* de treinamento para uma determinada classe freqüentemente são selecionados de uma mesma região através da delimitação de bordas. Estas regiões são chamadas de campo de treinamento.

c) Calcular os parâmetros de determinado algoritmo, utilizando os dados de treinamento. Estes parâmetros serão as propriedades de probabilidade do modelo utilizado ou serão utilizados em equações que definirão as separações no espaço espectral. O conjunto de parâmetros de uma determinada classe é muitas vezes chamado de assinatura daquelas classes.

d) Utilizar o classificador treinado para nomear cada *pixel* da imagem dentro de um dos tipos desejados de cobertura terrestre (classes de informação), classificando toda a imagem.

e) Produzir uma tabela sumarizada ou mapa temático (classe) que resume os resultados da classificação.

A seleção das amostras de treinamento é essencial para que o processo classificatório seja bem sucedido. É importante que as amostras sejam bastante homogêneas e representem toda a variação possível dentro da classe. Quando são utilizadas técnicas estatísticas de classificação, as amostras de treinamento devem ser grandes o suficiente para que possa ser feita a estimativa das características espectrais da classe de interesse. A partir de

então, no processo de classificação, todos os *pixels*, pertencentes ou não às amostras de treinamento deverão ser designados à classe para a qual a "probabilidade" de pertencerem é maior.

FIGURA 2.25 – REPRESENTAÇÃO DA CLASSIFICAÇÃO SUPERVISIONADA

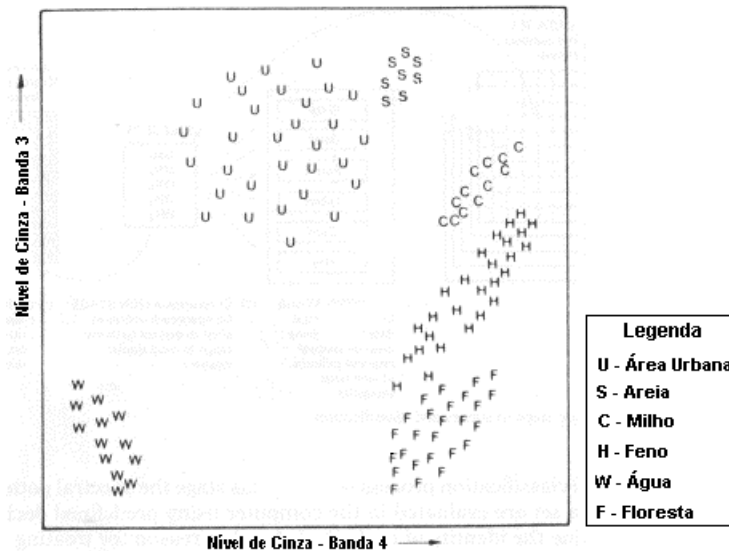


FONTE: Adaptado de SCHOWENGERDT, 1983

Alguns dos métodos estatísticos de classificação supervisionada mais conhecidos são: o do paralelepípedo, o da distância mínima e o da máxima verossimilhança (JENSEN, 1996; CURRAN, 1992), sendo que estes procedimentos podem ser aplicados a qualquer número de bandas. Entre os métodos supervisionados, optou-se pela máxima verossimilhança, a qual foi utilizada na comparação dos resultados gerados pelo método proposto. O detalhamento do método da máxima verossimilhança será ilustrado por meio de um exemplo simplificado de um subconjunto de dados multiespectrais das bandas 3 e 4, de forma a facilitar a explicação da técnica.

No espaço de atributos (Figura 2.26) é possível visualizar a distribuição dos valores de *pixels* de cada banda. Neste exemplo, os valores dos *pixels* da banda 4 são representados no eixo x e os valores dos *pixels* da banda 3 no eixo y. As observações de *pixel* mostradas na Figura 2.26 são de áreas de tipo de cobertura conhecido (locais de treinamento selecionados), sendo cada valor de *pixel* representado no espaço de atributos com uma letra que indica a classe que pertence. Vale ressaltar que os *pixels* de cada classe não possuem apenas um único valor, eles ilustram a tendência natural de variabilidade das propriedades espectrais encontradas dentro de cada classe de cobertura. Estas "nuvens de pontos" representam os valores de *pixel* semelhantes de cada classe de tipo de cobertura a ser interpretada (LILLESAND e KIEFER, 1994).

FIGURA 2.26 – *PIXELS* REPRESENTANDO SELEÇÃO DE LOCAIS DE TREINAMENTO EM UM ESPAÇO DE ATRIBUTOS



FONTE: Adaptado de LILLESAND e KIEFER, 1994

Com base na observação dos *pixels* das bandas 3 e 4 da imagem (Figura 2.26), será explicada a estratégia de classificação utilizando os "conjuntos de treinamento" para descrever os padrões de resposta espectrais da classe, de forma a identificar cada *pixel* da imagem na classe apropriada.


Segundo CURRAN (1992), no método da máxima verossimilhança inicialmente é calculada: a média dos níveis de cinza de cada classe dos dados de treinamento em cada banda, a variância e a correlação de cada classe de cobertura terrestre nos dados de treinamento, considerando que os dados de cada classe estão normalmente distribuídos (distribuição *gaussiana*). Com estas informações, o desvio dos *pixels* ao redor de cada vetor média pode ser descrito, utilizando a função de probabilidade.

O classificador então calcula estatisticamente a probabilidade de cada *pixel* de pertencer a determinada classe de treinamento, designando-o àquela cuja probabilidade é maior, podendo ser rotulado como "desconhecido" se os valores de probabilidade encontrados estiverem abaixo de um limiar definido pelo analista (CURRAN, 1992; LILLESAND e KIEFER, 1994).

Resumidamente, o classificador de máxima verossimilhança delinea "contornos equiprováveis" na forma elipsoidal no espaço de atributos. Estas regiões de decisão são apresentadas na Figura 2.27. A forma dos contornos equiprováveis expressa a sensibilidade do classificador de máxima verossimilhança para a covariância. Por exemplo, por causa desta sensibilidade, o *pixel* 1 é apropriadamente classificado como milho.

O classificador de máxima verossimilhança é executado assumindo igual probabilidade de ocorrência e custo de erro de classificação para todas as classes. Porém, se houver um conhecimento *a priori* de que as probabilidades não são iguais para todas as classes, é possível especificar fatores de peso para classes particulares. Esta variante da regra de decisão é conhecida como regra de decisão Bayesiana. Se não houver conhecimento *a priori* das probabilidades, recomenda-se não especificá-las, utilizando os pesos predefinidos da equação.

FIGURA 2.27 – CONTORNOS EQUIPROVÁVEIS DEFINIDOS PELA ESTRATÉGIA DO CLASSIFICADOR DA MÁXIMA VEROSSIMILHANÇA



FONTE: Adaptado de LILLESAND e KIEFER, 1994

2.2.6.2. Avaliação da separabilidade das classes

Os métodos estatísticos de avaliação da separabilidade entre classes consistem em

quantificar a possibilidade de discriminação entre diversas classes aplicando uma medida de distância estatística entre elas. Uma medida estatística muito utilizada é a divergência transformada que assume que os valores digitais de uma classe estão normalmente distribuídos, considerando a separabilidade como uma medida de discriminação entre as classes vizinhas e, gerando valores que se distribuem em um intervalo de 1 a 2000. Para o cálculo desta distância estatística são utilizados o vetor de médias e a matriz de variância-covariância entre pares de classes. Segundo JENSEN (1996), um valor de divergência transformada de 2000 sugere excelente separação de classes, acima de 1900 provê uma separação boa, porém abaixo de 1700 indica uma separação ruim entre classes. A fórmula para calcular a divergência transformada é a seguinte:

$$D_{ij} = \frac{1}{2} \text{tr}((C_i - C_j) - (C_i^{-1} - C_j^{-1})) + \frac{1}{2} \text{tr}((C_i^{-1} - C_j^{-1})(\mu_i - \mu_j)(\mu_i - \mu_j)^T) \quad (2.7)$$

$$DT_{ij} = 2000(1 - e^{\frac{-D_{ij}}{8}}) \quad (2.8)$$

onde:

i e j = assinaturas que estão sendo comparadas;

C_i = matriz de covariância da assinatura i ;

μ_i = vetor média da classe i ;

tr = função traço (álgebra matricial);

T = função transposta;

D_{ij} = divergência normal;


DT_{ij} = divergência transformada para as assinaturas i e j .

2.2.6.3. Classificação Não Supervisionada

Segundo RICHARDS e JIA (1999), a classificação não supervisionada (Figura 2.28) abrange algoritmos os quais nomeiam os *pixels* em uma imagem a classes espectrais sem que o usuário tenha conhecimento prévio dos nomes dessas classes. Neste tipo de

classificação, frequentemente são utilizados métodos de agrupamento (*clustering*). Estes procedimentos utilizam determinado algoritmo, conforme alguns critérios definidos, para determinar o número e localização das classes espectrais. O operador identifica essas classes *a posteriori*, analisando as assinaturas espectrais para determinar o que cada classe é ou representa, podendo ser necessária a verificação através de dados de referência disponíveis que poderiam incluir mapas e visitas a campo (JENSEN, 1996).

FIGURA 2.28 – REPRESENTAÇÃO DA CLASSIFICAÇÃO NÃO SUPERVISIONADA



FONTE: Adaptado de SCHOWENGERDT, 1983

A classificação não supervisionada é a opção mais adequada quando a área investigada é desconhecida, ou quando suas características não estão bem definidas (JENSEN, 1996; LILLESAND e KIEFER, 1994). Em determinados casos, o usuário não conhece o número de grupos espectrais presentes na imagem, nem o valor de dispersão interna ou de distância entre grupos (CHUVIECO, 1990). Desta forma, a análise não supervisionada se converte em um processo interativo onde o usuário estabelece alguns valores arbitrários que ele modifica conforme visualiza os resultados. A classificação não supervisionada pode ser útil também para determinar a composição da classe espectral dos dados antes da análise detalhada pela utilização de métodos de classificação supervisionada, sendo possível avaliar a potencialidade de discriminação de classes.

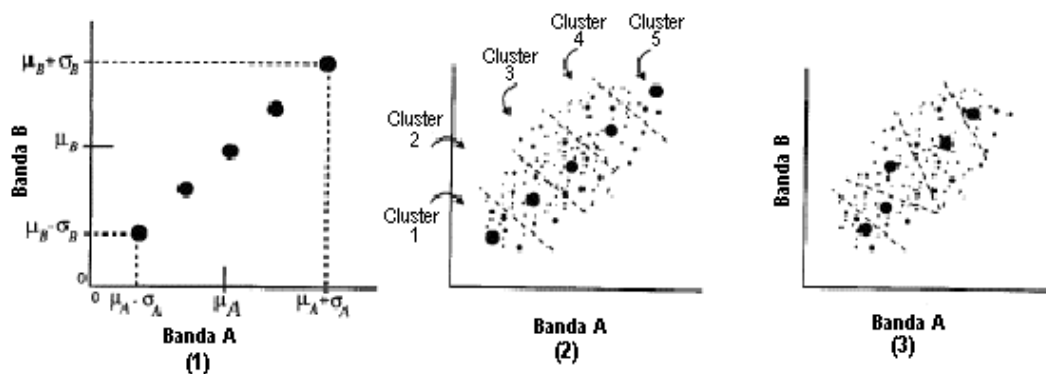
Segundo CHUVIECO (1990) existem diversas opções de algoritmos de agrupamento, porém um dos mais utilizados é denominado ISODATA (*Iterative Self Organizing Data Analysis*). O método ISODATA (Figura 2.29) utiliza a distância espectral mínima para nomear um agrupamento para cada *pixel* candidato. Este algoritmo é dito iterativo pois repetidamente executa uma classificação completa e recalcula estatísticas. Nesta

técnica, antes de iniciar o processo, são necessários alguns parâmetros de controle que deverão ser fornecidos como: o número máximo de agrupamentos; número mínimo de *pixels* em cada grupo; limiar de convergência, o qual se refere a porcentagem máxima permitida de *pixels* que poderão se manter inalterados entre as repetições distância mínima entre grupos; número máximo de repetições que deverão ser executadas. Este algoritmo pode ser resumido nos seguintes passos:

- a) Definir de forma arbitrária os centros de classe (*cluster*) de acordo com o número de agrupamentos indicado pelo usuário;
- b) Inserir cada *pixel* da imagem ao centro de classe mais próximo;
- c) Calcular os novos centros de classe, considerando os valores de todos os *pixels* que foram incorporados na fase anterior;
- d) Voltar a inserir cada *pixel* da imagem ao centro mais próximo, no qual devido ao deslocamento registrado em c), não tem porque coincidir com a designação anterior realizada em b);
- e) Voltar a calcular os centros de classe, tendo em conta as novas incorporações e retornar ao passo d).

O processo se repete iterativamente até que todos os centros de classe não se desloquem significativamente (limiar de convergência), indicando que se obteve um bom ajuste para os grupos presentes na imagem considerada ou até que o número máximo de iterações seja alcançado.

FIGURA 2.29 – EXEMPLO DE AGRUPAMENTO ISODATA

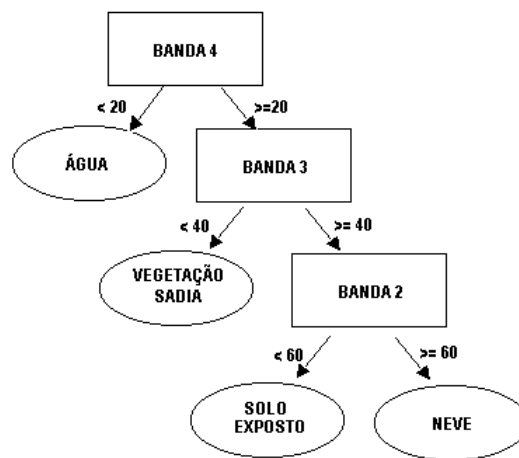


- (1) Cinco centros de classes definidos de forma arbitrária
- (2) Insere cada pixel da imagem ao centro de classe mais próximo
- (3) Calcula novos centros de classe

2.2.6.4. Classificação Baseada em Árvore de Decisão

Segundo CHUVIECO (1990), o objetivo de um classificador baseado em árvore de decisão é discriminar sequencialmente cada uma das classes, de acordo com a banda ou bandas que permitem uma melhor separação das demais. Esta estratégia de classificação tem a vantagem de ter uma execução muito rápida e de permitir conectar as características espectrais de cada cobertura. Na Figura 2.30 é apresentado um exemplo simplificado de um classificador de árvore de decisão, sendo utilizadas três bandas de um sensor, procurando-se obter a classificação de quatro classes de cobertura: água, vegetação sadia, solo exposto e neve. As regras que compõem a árvore de decisão podem ser geradas a partir da verificação dos *pixels* de um espaço de atributos, do histograma ou de qualquer outro tipo de análise que permita definir critérios específicos para separar as quatro classes de cobertura.

FIGURA 2.30 – EXEMPLO DE CLASSIFICADOR DE ÁRVORE DE DECISÃO



FONTE: Adaptado de CHUVIECO, 1990

Esta árvore de decisão pode ser resumida nas seguintes regras:

Se o valor do *pixel* na Banda 4 < 20 então Água

Se o valor do *pixel* na Banda 4 >= 20 e na Banda 3 < 40 então Vegetação Sadia

Se o valor do *pixel* na Banda 4 >= 20 e na Banda 3 >= 40 e na Banda 2 < 60 então

Solo Exposto

Se o valor do *pixel* na Banda 4 ≥ 20 e na Banda 3 ≥ 40 e na Banda 2 ≥ 60 então Neve

2.2.7. Avaliação da Classificação

Segundo LILLESAND e KIEFER (1994), na maioria dos estudos de classificação, a exatidão do resultado é avaliada por meio de uma matriz de erros de classificação (chamada também de matriz de confusão ou tabela de contingência). A matriz de erro compara os dados de referência que representam a "verdade terrestre" (obtidos a partir de verificação em campo, da interpretação de fotografias aéreas ou de informações geográficas a respeito do terreno) com os dados resultantes de uma classificação. Ao executar a avaliação da classificação, os dados de referência conhecidos devem abranger outros conjuntos de dados diferentes dos utilizados para treinar o classificador. As amostras de treinamento podem ser utilizadas como dados de referência somente quando deseja-se avaliar se as amostras foram corretamente classificadas.

A matriz de erro (Tabela 2.3) é sempre quadrada tendo o número de linhas e colunas igual ao número de classes que estão sendo avaliadas. As linhas representam o resultado da classificação e as colunas os dados de referência ("verdade terrestre"). Os conjuntos de *pixels* corretamente classificados ficam situados ao longo da diagonal principal da matriz.

TABELA 2.3 – REPRESENTAÇÃO DA MATRIZ DE ERRO

		Dados de Referência ("Verdade Terrestre")				
		Classe 1	Classe 2	...	Classe N	Total Linha
Dados Classificados	Classe 1	a_{11}	a_{12}	...	a_{1n}	$\sum_{K=1}^N a_{1K}$
	Classe 2	a_{21}	a_{22}	...	a_{2n}	$\sum_{K=1}^N a_{2K}$

	Classe N	a_{n1}	a_{n2}	...	a_{nn}	$\sum_{K=1}^N a_{nK}$
Total Coluna	$\sum_{K=1}^N a_{K1}$	$\sum_{K=1}^N a_{K2}$		$\sum_{K=1}^N a_{KN}$	$N = \sum_{I,K=1}^N a_{IK}$	

FONTE: Adaptado de: LILLESAND e KIEFER, 1994

Várias características sobre o desempenho de classificação são expressas em uma matriz de erro. Por exemplo, pode-se estudar os vários erros de classificação de omissão ou exclusão. Erros de omissão ocorrem quando um *pixel* não é atribuído à classe à qual pertence. Erros de comissão ou inclusão ocorrem quando o *pixel* é atribuído a uma classe à qual não pertence. Todos os elementos não contidos na diagonal da matriz representam erros de omissão ou comissão. Cada erro representa uma omissão da classe correta e uma comissão para uma classe incorreta. Através da matriz de erro, podem ser avaliados vários índices de exatidão como: global, do usuário e do produtor. A seguir são detalhados os três índices de exatidão, bem como seus respectivos métodos de cálculo.

A exatidão global é a proporção de todos os pixels de referência que foram classificados corretamente. É calculada dividindo-se o número total de *pixels* corretamente classificados (a soma dos elementos ao longo da diagonal principal) pelo número total de *pixels* de referência. A exatidão global gera uma medida total, não informando sobre quais classes foram melhor classificadas.

A exatidão do produtor é uma medida de erro de omissão e indica a probabilidade de um pixel de determinada cobertura terrestre dos dados de referência ser corretamente classificado. Esta exatidão é o resultado da divisão do número de *pixels* corretamente classificados em cada classe (diagonal principal) pelo número total de *pixels* na coluna correspondente (número de conjuntos de *pixels* de treinamento usados para aquela classe).

A exatidão do usuário é uma medida de erro de comissão e indica a probabilidade de um *pixel* classificado em uma determinada classe, realmente pertencer àquela cobertura terrestre. Esta exatidão é o resultado da divisão do número de *pixels* corretamente classificados em cada classe (diagonal principal) pelo número total de *pixels* na linha correspondente (número total de *pixels* que foram classificados naquela classe).

Uma questão fundamental na análise dos valores da matriz de erro é a relação existente entre as observações que são usadas para treinar o classificador (e que constituem a amostra de treinamento) e as observações usadas para construir a matriz de confusão e avaliar a precisão do classificador (amostra de teste). Se ambas as amostras estiverem correlacionadas

então os valores de precisão serão superestimados. A situação extrema é aquela em que se utiliza a mesma amostra para construir o classificador e a matriz de erro. A estimativa de precisão obtida nesse caso designa uma precisão aparente e pode atingir valores muito superiores ao verdadeiro valor de precisão do classificador para os dados analisados.

2.2.7.1. Coeficiente Kappa

Ao interpretar a exatidão de classificação, até mesmo uma atribuição arbitrária de *pixels* pode produzir porcentagem de valores corretos na matriz de erro. Na realidade, tal tarefa arbitrária poderia gerar um resultado de classificação aparentemente bom (LILLESAND e KIEFER, 1994). A matriz de confusão permite o cálculo de vários índices de precisão. O mais conhecido e indicado para classificações temáticas por representar toda a matriz confusão é o coeficiente Kappa (k). Este índice considera todos os elementos da matriz de confusão, ao invés de somente utilizar os elementos da diagonal, como ocorre com a maioria dos índices. O caso ideal ocorre quando o resultado do índice k aproxima-se de 1, pois o mesmo varia normalmente entre 0 e 1. O índice Kappa é calculado como:

$$k = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \cdot x_{+i})} \quad (2.9)$$

Onde:

r = número de linhas na matriz de erro

x_{ii} = o número de observações na linha i e coluna i (na diagonal principal)

x_{i+} = total de observações na linha i (mostrado como total da margem direita da matriz)

x_{+i} = total de observações na coluna i (mostrado como total da margem de baixo da matriz)

N = número total de observações incluídas na matriz

2.3. LÓGICA NEBULOSA

2.3.1. Definição

A lógica nebulosa abrange um conjunto de conceitos e metodologias que permitem processar informações subjetivas (ZADEH, 1965). Do ponto de vista prático, esta lógica tem como objetivo o desenvolvimento de métodos simples e robustos para aproveitar ativamente os dados imprecisos, qualitativos e vagos, geralmente descartados pelas abordagens tradicionais.

Segundo ZADEH (1965): “Os seres humanos raramente usam números para resolver problemas”. Assim, modelar frases e estimativas humanas através de formalismos matemáticos, não é um procedimento facilmente realizado. A partir destas observações, ZADEH (1965) concluiu que quando a complexidade do sistema aumenta, a habilidade para tornar as proposições precisas diminui até um limiar que está fora do alcance. A lógica nebulosa proporciona uma linguagem natural, onde predomina o raciocínio aproximado com proposições imprecisas, utilizando a teoria de conjuntos nebulosos como a principal ferramenta, sendo análoga ao papel da lógica de predicado, utilizada para raciocínio com proposições precisas (KLIR e FOLGER, 1988).

2.3.2. Conjuntos Nebulosos

Na teoria de conjuntos clássica, o conjunto (*crisp*) é definido de tal modo como se dividisse os indivíduos de determinado conjunto universo em dois grupos: 1. membros (esses que certamente pertencem ao conjunto) e 2. não-membros (esses que certamente não fazem parte do conjunto). Uma acentuada distinção de não ambiguidade existe entre os membros e não membros da classe ou categoria representada pelo conjunto *crisp* (KLIR e FOLGER, 1988). A teoria de conjuntos *crisp* é a mais utilizada, porém muitas categorias (por exemplo, em idioma natural), como as classes de pessoas altas, carros caros, números muito maiores do

que 1, não exibem esta característica binária (verdadeiro ou falso). Ao invés disso, os seus limites parecem vagos, e a transição de membro para não membro é gradual ao invés de abrupta (KLIR e FOLGER, 1988).

O termo conjunto nebuloso (*fuzzy*) foi introduzido em 1965 por Lotfi Zadeh (ZADEH, 1965), como um novo caminho para representar a incerteza na vida cotidiana (BEZDEK e PAL, 1992). Os conjuntos nebulosos (ZADEH, 1965) também chamados conjuntos nebulosos, permitem representar conceitos vagos, expressos em linguagem natural, tais como, pequeno, quente, bom, ruim, dentre outros.

2.3.2.1. Conceitos Básicos

Uma noção básica da teoria de conjuntos é a pertinência de um elemento a um determinado conjunto. Assim, sendo x um elemento pertencente a um conjunto A , representa-se por $x \in A$. Uma forma de se indicar essa pertinência pode ser feita através da função de pertinência (*membership function*) $\mu_A(x)$, cujo valor indica se o elemento x pertence ou não ao conjunto A . Por exemplo, no seguinte caso, $\mu_A(x)$ é uma função de pertinência binária ou *crisp*, sendo a sua pertinência dada por um valor em $\{0,1\}$:


$$\begin{aligned} \mu_A(x) &= 1, & \text{se } x \in A \\ \mu_A(x) &= 0, & \text{se } x \notin A \end{aligned} \quad (2.10)$$

Mas, no seguinte caso, $\mu_A(x)$ é uma função de pertinência nebulosa, pois associa para cada elemento x , pertencente a A , um número real $\mu_A(x)$ no intervalo $[0,1]$, indicando o grau de pertinência do elemento x ao conjunto A (SHAW e SIMÕES, 1999). Quanto mais o valor de $\mu_A(x)$ se aproximar de 1, maior será o grau de pertinência do elemento ao conjunto A .

$$\begin{aligned} \mu_A(x) &\geq 0, & \text{se } x \in A \\ \mu_A(x) &= 0, & \text{se } x \notin A \end{aligned} \quad (2.11)$$

Ao observar a Figura 2.31, pode-se notar que ao mover o pixel 2 em direção ao limite do conjunto Floresta, passando do ponto de cruzamento, ocorrerá subitamente uma mudança no comportamento de sua pertinência, originalmente de não-membro do conjunto Floresta para membro. Em conjuntos *crisp*, a pertinência de um elemento que esteja exatamente nos limites é indeterminada (SHAW e SIMÕES, 1999), porém em conjuntos nebulosos, um elemento que esteja exatamente nos limites terá grau de pertinência 0.5 em relação ao conjunto.

FIGURA 2.31 - REPRESENTAÇÃO DA PERTINÊNCIA DE UM PIXEL A UMA DETERMINADA CLASSE



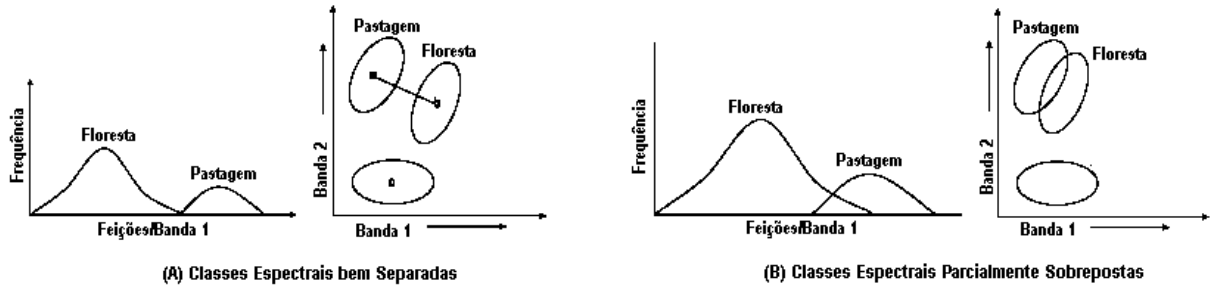
FONTE: Adaptado de: SHAW e SIMÕES, 1999

Um problema típico desta pertinência parcial é retratado na Figura 2.32, que representa o problema típico do “pixel mistura”, o qual pode pertencer parcialmente a duas classes distintas. Na Figura 2.32-A podem-se observar classes espectrais bem separadas para diferentes tipos de cobertura terrestre, o que proporciona grupos de pixels bem separados no espaço de atributos. Porém, na Figura 2.32-B, os diferentes tipos de cobertura tem classes espectrais semelhantes, acarretando grupos de pixels parcialmente sobrepostos no espaço de atributos.

Um conjunto nebuloso pode ser definido matematicamente, nomeando a cada possível elemento no conjunto universo um valor que representa seu grau de pertinência, correspondendo ao grau para o qual aquele elemento é semelhante ou compatível com o conceito representado pelo conjunto nebuloso. Devido aos conjuntos nebulosos representarem a pertinência total e a não pertinência total indicadas pelos valores de 1 e 0, respectivamente;

pode-se considerar o conjunto *crisp* como um caso específico de conjunto nebuloso, para o qual são permitidos somente estes dois graus de pertinência (KLIR e FOLGER, 1988).

FIGURA 2.32 - REPRESENTAÇÃO DE CLASSE ESPECTRAIS DISTINTAS E SEMELHANTES



Segundo BEZDEK e PAL (1992), a linguagem utilizada no dia a dia é um exemplo de modo de incerteza que é usado e propagado. Este tipo de incerteza é chamado *fuzziness* ou nebulosidade, pois permite infinitos valores no intervalo $[0,1]$. Os conjuntos nebulosos introduzem incerteza (com o objetivo de reduzir complexidade), através da eliminação do limite acentuado que divide os membros da classe de não membros (KLIR e FOLGER, 1988).


Para ilustrar algumas definições, serão considerados os graus de pertinência dos elementos de um conjunto universo pequeno com quatro diferentes conjuntos nebulosos, como listado na Tabela 2.4. O mesmo conjunto está graficamente expresso na Figura 2.33, a qual exhibe o intervalo de valores de pixel na coordenada x e os graus de pertinência na coordenada y . Neste caso, o conjunto *crisp* do universo X de *pixels* da banda A foram selecionados é: $X = \{1, 2, 3, 4, 5, 6, 7, 8\}$ e os conjuntos nebulosos foram definidos como água, floresta, pastagem e solo.

TABELA 2.4 - CONJUNTOS NEBULOSOS DE *PIXELS DA BANDA A*

Banda A (valor de <i>pixel</i>)	Água	Floresta	Pastagem	Solo
1	0	1	0	0
2	0	1	0	0
3	0	0.8	0.8	0.1
4	0	0.5	1	0.2
5	0	0.2	1	0.4
6	0	0.1	1	0.6
7	0	0	1	0.8
9	0	0	1	1

FONTE: Adaptado de: KLIR e FOLGER, 1988

FIGURA 2.33 – REPRESENTAÇÃO DOS CONJUNTOS NEBULOSOS DA TABELA 2.4



FONTE: ADAPTADO DE: KLIR E FOLGER, 1988

2.3.2.1.1. Conjunto suporte

O conjunto suporte de um conjunto nebuloso A é o conjunto *crisp* que contém todos os elementos do universo X que possuem um grau de pertinência superior a zero em A (KLIR e FOLGER, 1988), ou seja, $\text{sup } A = \{x \in X \mid \mu_A(x) > 0\}$. No caso do exemplo (Tabela 2.4), o suporte do conjunto nebuloso floresta é o conjunto *crisp*: $\text{sup}(\text{floresta}) = \{1,2,3,4,5,6\}$. Um conjunto nebuloso vazio tem um suporte vazio, sendo a função de pertinência atribuindo 0 para todos elementos do conjunto universal. O conjunto nebuloso água como definido (Tabela 2.4) é um exemplo de um conjunto nebuloso vazio dentro do universo escolhido (KLIR e FOLGER, 1988).

Uma notação especial que é freqüentemente usada na literatura definindo conjuntos nebulosos como um suporte finito, assume que x_i é um elemento do suporte do conjunto nebuloso A e que μ_i é seu grau de pertinência em A (KLIR e FOLGER, 1988). Assim, um conjunto nebuloso A em X é um conjunto de pares ordenados:

$$A = \mu_1 / x_1 + \mu_2 / x_2 + \dots + \mu_n / x_n \quad \text{ou} \quad A = \{\mu_A(x) / x\} \quad (2.12)$$

Onde a barra é empregada para ligar os elementos do suporte com seus graus de pertinência em A e o sinal de adição indica, em lugar de qualquer tipo de adição algébrica, que os pares listados de elementos e graus de pertinência coletivamente formam a definição do conjunto A. Para o caso em que um conjunto nebuloso A é definido no conjunto universal que é finito e calculável, pode-se escrever :

$$A = \sum_{i=1}^n \mu_i / x_i \quad (2.13)$$

2.3.2.1.2. Peso e Normalização

O peso de um conjunto nebuloso é o maior grau de pertinência alcançado por algum elemento no conjunto (KLIR e FOLGER, 1988). A normalização de um conjunto de números (ou de uma função) é encontrada ao dividir cada número do conjunto pelo maior número, tornando-se o maior número igual a 1 (KARTALOPOULOS, 1996). Por exemplo, o conjunto de níveis de cinza (30, 50, 80, 100, 70, 40) é normalizado para (0.3, 0.5, 0.80, 1.0, 0.70, 0.40) se for dividido cada número por 100.

Portanto, um conjunto nebuloso é chamado normalizado quando pelo menos um de seus elementos atinge o máximo grau de pertinência possível. Se a faixa dos graus de pertinência é um intervalo fechado entre 0 e 1, por exemplo, então pelo menos um elemento deve ter um grau de pertinência de 1 para o conjunto nebuloso ser considerado normalizado (KLIR e FOLGER, 1988). Claramente, isto também implicará que o peso do conjunto nebuloso seja igual a 1. Os três conjuntos nebulosos: floresta, pastagem e solo da Tabela 2.4 são todos normalizados, e assim o peso de cada é igual a 1.

2.3.2.1.3. Conjunto de nível (α -cut)

Um α -cut de um conjunto nebuloso A é um conjunto *crisp* A_α que contém todos os elementos do conjunto universal que possuem um grau de pertinência em A igual ou superior ao valor especificado de α (ZADEH, 1965), sendo representado como

$$A_\alpha = \{x \in X \mid \mu_A(x) \geq \alpha\}.$$

O valor α pode ser escolhido arbitrariamente, mas é freqüentemente designado para os valores de graus de pertinência no conjunto nebuloso que está sendo analisado (KLIR e FOLGER, 1988). Por exemplo, considerando α -cut do conjunto nebuloso floresta (Tabela 2.4) é o conjunto *crisp*: a) para $\alpha=0.2$: $Floresta_{0.2}=\{1, 2, 3, 4, 5\}$; b) para $\alpha=0.8$: $Floresta_{0.8}=\{1, 2, 3\}$ e, c) para $\alpha = 1$: $Floresta_1 = \{1, 2\}$.

2.3.2.1.4. Cardinalidade

A cardinalidade escalar de um conjunto nebuloso A definida no conjunto universal finito X é a somatória dos graus de pertinência de todos os elementos de X em A , isto é, $|A| = \sum_{x \in X} \mu_A(x)$ (KLIR e FOLGER, 1988). Portanto, no exemplo (Tabela 2.4), a cardinalidade escalar do conjunto nebuloso solo é: $|\text{solo}| = 0 + 0 + 0.1 + 0.2 + 0.4 + 0.6 + 0.8 + 1 = 3.1$ e a cardinalidade escalar do conjunto nebuloso água é 0.

2.3.2.1.5. Subconjunto

Se o grau de pertinência de cada elemento do conjunto universal X em um conjunto nebuloso A é menor ou igual ao seu grau de pertinência no conjunto nebuloso B , então A é chamado um subconjunto de B (KLIR e FOLGER, 1988). Assim, se $\mu_A(x) \leq \mu_B(x)$ para todo $x \in X$, então $A \subseteq B$. O conjunto nebuloso solo (Tabela 2.4) é um subconjunto do conjunto nebuloso pastagem para cada elemento no conjunto universal: $\mu_{\text{solo}}(x) \leq \mu_{\text{pastagem}}(x)$.

2.3.2.1.6. Conjuntos iguais x conjuntos diferentes


Conjuntos nebulosos A e B são chamados iguais se $\mu_A(x) = \mu_B(x)$ para todo elemento $x \in X$. Isto é indicado por $A = B$. Claramente, se $A = B$, então $A \subseteq B$ e $B \subseteq A$ (KLIR e FOLGER, 1988). Se conjuntos nebulosos A e B são diferentes $\mu_A(x) \neq \mu_B(x)$ para

pelo menos um $x \in X$ representa-se por $A \neq B$. Nenhum dos quatro conjuntos nebulosos definidos (Tabela 2.4) é igual a ao outro.

2.3.2.1.7. Tipos de funções de pertinência

Na maioria das aplicações práticas, as funções de pertinência são do tipo gaussiana, triangulares, trapezoidais, crescentes ou decrescentes. A Figura 2.34 apresenta estes cinco tipos de funções de pertinência.

FIGURA 2.34 – REPRESENTAÇÃO DOS TIPOS DE FUNÇÕES DE PERTINÊNCIA NEBULOSAS



2.3.2.2. Conjunto Nebuloso x Probabilidade

Conjunto nebuloso é freqüentemente indicado incorretamente como alguma forma de probabilidade. Apesar do fato de poderem assumir valores semelhantes, é importante perceber que os graus de pertinência não são probabilidades. Uma diferença imediatamente aparente é que a adição de probabilidades em um conjunto universal finito, tem de ser igual a 1, enquanto não há nenhuma exigência desta para graus de pertinência. O exemplo a seguir relatado por BEZDEK (1996) esclarece a diferença entre conjunto nebuloso e probabilidade.

Considerando que L = conjunto de todos os líquidos e o subconjunto P = todos os líquidos potáveis. Se uma determinada pessoa estivesse sem beber há muito tempo e encontrasse duas garrafas A e B , marcadas com a seguinte informação: $\text{prob}(A \in P) = 0.91$ e $\text{memb}(B \in P) = 0.91$. Concluindo-se que esta pessoa deve beber a que escolher, qual seria a escolhida para se beber primeiro? A maioria das pessoas diria que B poderia conter, por exemplo, água de pântano; porém uma pertinência de 0.91 significa que os conteúdos de B são "bastante semelhantes" a líquidos perfeitamente potáveis (talvez, água pura). Por outro

lado, a probabilidade de A ser potável=0.91, simplesmente indica, que baseado em longas experiências nos conteúdos de A, é esperado que seja potável em aproximadamente 91% das tentativas, sendo que, em 9% das tentativas restantes, os conteúdos poderão ser mortais, isto é, aproximadamente 1 probabilidade em 10. Assim, a maior parte das pessoas optaria pela água de pântano da garrafa B. Continuando, então, ao examinar-se os conteúdos das garrafas A e B, descobre-se que A e B contém cerveja. Depois desta observação, o valor de pertinência para B não mudará, entretanto o valor da probabilidade deve, reduzir-se de 0.91 a 0. Este exemplo mostra que estes dois modelos possuem diferentes espécies de informação: pertinência nebulosa, que representa similaridades de objetos para definir propriedades imprecisas e probabilidade que diz respeito a informações de frequências relativas.

2.3.2.4. Operações sobre Conjuntos Nebulosos


Na teoria de conjuntos clássica, as operações sobre conjuntos produzem um outro conjunto. Do mesmo modo que o cálculo proposicional, com suas operações de conjunção, disjunção, negação e condicional está associado a conjuntos *crisp*, a lógica nebulosa com as mesmas operações está associada aos conjuntos nebulosos. Em ZADEH (1965) foram introduzidas as definições para as operações de complemento, intersecção e união, sendo estes chamados de operadores clássicos.

2.3.2.4.1. Complemento

O complemento de um conjunto nebuloso com respeito ao conjunto universal X é indicado por $\neg\mu_A(x)$, podendo ser definido por $\neg\mu_A(x) = 1 - \mu_A(x) \quad \forall x \in A$, quando o intervalo de graus de pertinência é um intervalo fechado entre 0 e 1. Assim, se um elemento tem um grau de pertinência de 0.8 em um conjunto nebuloso A, seu grau de pertinência no complemento de A será 0.2. Por exemplo, obtendo o complemento do conjunto nebuloso solo (Tabela 2.4), produz-se o conjunto não solo (Figura 2.35) definido como:

$$\text{Não solo} = 1/1 + 1/2 + 0.9/3 + 0.8/4 + 0.6/5 + 0.4/6 + 0.2/7 + 0/8$$

FIGURA 2.35 – REPRESENTAÇÃO DO COMPLEMENTO DE UM CONJUNTO NEBULOSO



FONTE: Adaptado de: KLIR e FOLGER, 1988

A Figura 2.35 mostra que o conjunto solo e o seu complemento não solo, são em geral, não disjuntos, ou seja, que sua intersecção não é o conjunto vazio (SHAW e SIMÕES, 1999). Assim, solo e não solo possuem uma parte em comum:

$$\mu_A(x) \cap \neg\mu_A(x) \neq \phi \quad (2.14)$$

2.3.2.4.2. Operação de Intersecção

A intersecção ou conjunção (and) de dois conjuntos nebulosos A e B, com suas funções de pertinência $\mu_A(x)$ e $\mu_B(x)$ é especificada em geral por um mapeamento binário T, que agrega duas funções de pertinência como:

$$\mu_{A \cap B}(x) = T(\mu_A(x), \mu_B(x)) \quad (2.15)$$

Por exemplo, o operador binário T pode representar a multiplicação de $\mu_A(x)$ e $\mu_B(x)$. Estes operadores de intersecção nebulosos que são geralmente referenciados como T-norma e, satisfazem algumas exigências básicas. Um operador T-norma é um mapeamento binário T (...) que satisfaz as seguintes propriedades:

$$\text{Limite: } T(0,0) = 0, \quad T = (a,1) = T(1,a) = a \quad (2.16)$$

$$\text{Monotonicidade: } T(a,b) \leq T(c,d) \text{ se } a \leq c \text{ e } b \leq d \quad (2.17)$$

$$\text{Comutatividade: } T(a,b) = T(b,a) \quad (2.18)$$


$$\text{Associatividade: } T(a,T(b,c)) = T(T(a,b),c) \quad (2.19)$$

A propriedade (a) impõe a generalização correta a conjuntos nebulosos. A propriedade (b) indica que uma redução nos valores de pertinência em A ou B não podem produzir um incremento no valor de pertinência em A interseção de B. A propriedade (c) indica que o operador é indiferente à ordem dos conjuntos nebulosos que serão combinados. Finalmente, a propriedade (d) permite efetuar a interseção de qualquer número de conjuntos em qualquer ordem de agrupamentos de pares.

Quando a interseção de dois conjuntos nebulosos é dada por $\mu_{A \cap B}(x) = \min[\mu_A(x), \mu_B(x)] = \mu_A(x) \wedge \mu_B(x)$, o grau de pertinência de cada elemento do conjunto universal em $A \cap B$ é o menor valor entre o grau de pertinência em A e seu grau de pertinência em B, assim o conjunto nebuloso $A \cap B$ é um subconjunto de ambos A e B. Ao obter-se a interseção dos conjuntos nebulosos floresta e solo (Tabela 2.6), utilizando a t-norma min, o seguinte conjunto nebuloso é criado (Figura 2.36):

$$\text{Floresta} \cap \text{Solo} = 0/1 + 0/2 + 0.1/3 + 0.2/4 + 0.2/5 + 0.1/6 + 0/7 + 0/8$$

FIGURA 2.36 – REPRESENTAÇÃO DA INTERSECÇÃO DE CONJUNTOS NEBULOSOS



FONTE: ADAPTADO DE: KLIR E FOLGER, 1988

2.3.2.4.3. Operação de União

A união ou disjunção (or) de dois conjuntos nebulosos A e B, com suas funções de pertinência $\mu_A(x)$ e $\mu_B(x)$, é especificada em geral por um mapeamento binário S, que agrega duas funções de pertinência como:

$$\mu_{A \cup B}(x) = S(\mu_A(x), \mu_B(x)) \quad (2.20)$$

Por exemplo, o operador binário S pode representar a adição de $\mu_A(x)$ e $\mu_B(x)$. Estes operadores de união nebulosos que são frequentemente referenciados como T-conorma ou S-norma, devem satisfazer algumas exigências básicas. Um operador S-norma é um mapeamento binário S (.,.) que satisfaz as seguintes propriedades:

$$\text{Limite: } S(1,1) = 1, \quad S(a,0) = S(0,a) = a \quad (2.21)$$

$$\text{Monotonicidade: } S(a,b) \leq S(c,d) \text{ se } a \leq c \text{ e } b \leq d \quad (2.22)$$

$$\text{Comutatividade: } S(a,b) = S(b,a) \quad (2.23)$$


$$\text{Associatividade: } S(a, S(b,c)) = S(S(a,b), c) \quad (2.24)$$

A propriedade (a) impõe a generalização correta a conjuntos nebulosos. A propriedade (b) indica que uma redução nos valores de pertinência em A ou B não podem produzir um incremento no valor de pertinência em A união de B. A propriedade (c) indica que o operador é indiferente à ordem dos conjuntos nebulosos que serão combinados. Finalmente, a propriedade (d) permite efetuar a união de qualquer número de conjuntos em qualquer ordem de agrupamentos de pares.

Quando a união de dois conjuntos nebulosos é dada por $\mu_{A \cup B}(x) = \max[\mu_A(x), \mu_B(x)] = \mu_A(x) \vee \mu_B(x)$, o grau de pertinência de cada elemento do conjunto universal em $A \cup B$ é o maior valor entre o grau de pertinência em A e seu grau de pertinência em B, assim os conjuntos nebulosos A e B são ambos subconjuntos do conjunto nebuloso $A \cup B$. Ao obter-se a união dos conjuntos nebulosos floresta e solo (Tabela 2.4) utilizando a t-conorma max, o seguinte conjunto nebuloso é criado (Figura 2.37):

$$\text{Floresta} \cup \text{Solo} = 1/1 + 1/2 + 0.8/3 + 0.5/4 + 0.4/5 + 0.6/6 + 0.8/7 + 1/8 + 1/9$$

FIGURA 2.37 – REPRESENTAÇÃO DA UNIÃO DE CONJUNTOS NEBULOSOS



FONTE: Adaptado de: KLIR e FOLGER, 1988

Algumas operações T-normas e T-conormas estão listadas na Tabela 2.5, entretanto, estas operações não são a única alternativa para estender as operações clássicas. Muitos operadores têm sido propostos para modelar a união e a interseção de conjuntos difusos, sendo que diferentes definições produzirão conjuntos de saídas distintos também.

Tabela 2.5 – T-NORMAS E T-CONORMAS DUAIS

T-normas	T-conormas
$\min(a,b)$	$\max(a,b)$
$a.b$	$a+b$
$\max(a+b-1,0)$	ab
$a, \text{ se } b=1$	$\min(a+b,1)$
$b, \text{ se } a = 1$	$a, \text{ se } b=0$
$0, \text{ senão}$	$b, \text{ se } a = 0$
	$1, \text{ senão}$

FONTE: Adaptado de: SHAW e SIMÕES, 1999

2.3.3. Sistemas Nebulosos

Sistemas nebulosos são baseados na lógica nebulosa e nos conjuntos nebulosos, propostos por ZADEH (1965). Estes sistemas são caracterizados pela inferência de regras (SE-ENTÃO) nebulosas, que são uma forma clara e eficiente de representar o conhecimento

(SHAW e SIMÕES, 1999). Estas regras são facilmente entendidas, pois por serem estruturadas próximas à linguagem natural usada pelos especialistas, permitem a manipulação de variáveis lingüísticas. Uma regra simples em processamento de imagens, por exemplo, seria:


SE Banda 4 está no intervalo [0,13] ENTÃO classe é Água

Uma variável lingüística é uma variável na qual valores são representados por palavras ao invés de números. Neste caso, a lógica nebulosa pode ser vista como uma metodologia para calcular com palavras ao invés de números. Embora palavras sejam inerentemente menos precisas que números, o uso delas é mais próximo da intuição humana. Representar o ambiente em termos próximos a linguagem natural, permite que a falta de precisão possa ser tratada de forma apropriada. Devido a estes aspectos, os sistemas nebulosos podem resolver problemas altamente imprecisos, sendo aplicados em vários sistemas de controle, de suporte à decisão e previsão (SHAW e SIMÕES, 1999).

A lógica nebulosa permite o uso de predicados nebulosos (caro, velho, raro, perigoso e outros), quantificadores nebulosos (muito, pouco, quase tudo, normalmente e igual), valores verdade nebulosos (totalmente verdadeiro, muito verdadeiro, mais ou menos verdadeiro, principalmente falso, e assim sucessivamente), e vários outros tipos de modificadores nebulosos (tais como provável, quase impossível, extremamente improvável) (KLIR e FOLGER, 1988). Cada simples predicado nebuloso, é representado em lógica nebulosa por um conjunto nebuloso, representado por $x \in P$. Considerando, por exemplo, que x representa um nível de cinza de um *pixel* e que P tem o significado de escuro, tem-se: "*Pixel* é escuro". Então, assumindo que o conjunto universal é o conjunto de inteiros de 0 até 60, representando diferentes níveis de cinza, o predicado pode ser representado por lógica nebulosa, onde a função de pertinência é apresentada na Figura 2.38. O valor verdade desta proposição depende do grau de pertinência do nível de cinza do *pixel* no conjunto nebuloso escolhido para caracterizar o conceito de escuro (KLIR e FOLGER, 1988). Assim, neste caso $a = \mu_{\text{Escuro}}(x)$ para cada $x \in X$, e em relação ao *pixel* com nível de cinza = 25, obtém-se $\mu_{\text{Escuro}}(25)=0.87$ (KLIR e FOLGER, 1988).

Pode-se manipular conjuntos nebulosos para representar predicados com algumas das operações básicas de conjuntos nebulosos de complemento, união e intersecção. Além disso, estes conjuntos podem ser modificados por operadores especiais correspondendo a termos lingüísticos tais como muito, mais ou menos e outros. Estes termos são freqüentemente chamados de alturas lingüísticas. Por exemplo, aplicando a altura lingüística muito para o conjunto nebuloso rotulado como escuro na Figura 2.38, obtém-se um novo conjunto nebuloso representando o conceito de um *pixel* muito escuro, que é especificado na mesma figura (2.38) como $\mu_{\text{MuitoEscuro}}(25)=0.36$ (KLIR e FOLGER, 1988).

FIGURA 2.38 – REPRESENTAÇÃO DO CONJUNTO NEBULOSO ESCURO E MUITO ESCURO



FONTE: ADAPTADO DE: KLIR E FOLGER, 1988

2.3.3.1. Etapas de um Sistema Nebuloso

As etapas de um sistema nebuloso correspondem a fuzzificação, a inferência de regras e a defuzzificação, conforme apresentado na Figura 2.39. Como geralmente os dados de entrada são valores *crisp*, resultados de medições ou observações, é necessário efetuar-se o mapeamento destes dados para os conjuntos nebulosos de entrada relevantes, o que é realizado no estágio de fuzzificação. Neste estágio ocorre também a ativação das regras relevantes para uma dada situação. No processo de inferência ocorrem as operações com conjuntos nebulosos propriamente ditas: agregação de cada componente da regra e combinação das várias regras. Uma vez obtido o conjunto nebuloso de saída através do

processo de inferência, no estágio de defuzzificação é efetuada uma interpretação dessa informação.

FIGURA 2.39 –ETAPAS DE UM SISTEMA NEBULOSO



2.3.6.1.1. Fuzzificação

Na etapa de fuzzificação são realizadas a análise do ambiente pois é de extrema importância conhecer: o problema a ser manipulado; como o especialista trabalha e como ele entende sua realidade; qual a linguagem usada pelo especialista para tratar os problemas; quais as decisões e quando elas são tomadas. A partir da aquisição deste conhecimento, pode-se saber em qual contexto o sistema baseado em lógica nebulosa será aplicado.

Como geralmente os dados de entrada são valores resultantes de medidas ou observações, é necessário efetuar-se o mapeamento (fuzzificação) (SHAW E SIMÕES, 1999) destes dados para os conjuntos nebulosos de entrada relevantes. Desta forma, são definidos os conjuntos nebulosos, escolhendo qual o tipo de função de pertinência a ser adotada (triangular, gaussiano, etc.) e as variáveis lingüísticas. A fuzzificação então descreve a transição de um sistema *crisp* para um sistema nebuloso, assinalando os valores de pertinência entre 0 e 1 para cada característica, sendo estes chamados de funções de pertinência.

2.3.6.1.2. Inferência de Regras

Nesta etapa são definidas as regras, com base no conhecimento adquirido do problema a ser solucionado. As regras em um sistema nebuloso são expressas na forma de proposições (SHAW e SIMÕES, 1999), tais como:

*SE Banda1 é Alto <conectivo1> Banda2 é Alto ENTÃO x é Classe A
<conectivo2>*

SE Banda1 é Médio <conectivo1> Banda2 é Médio ENTÃO x é Classe B

Onde:

Banda1 e Banda2: são variáveis de entrada (valores conhecidos);

x: é uma variável de saída (um valor a ser calculado);

Alto: é um valor linguístico com sua respectiva função de pertinência (conjunto nebuloso) definida na Banda1 e 2;

Médio: é um valor linguístico com sua respectiva função de pertinência (conjunto nebuloso) definida na Banda1 e 2;

Classe A: é um valor linguístico com sua respectiva função de pertinência (conjunto nebuloso) definida em x

Conectivo1 e Conectivo2: são os operadores lógicos escolhidos para se expressar a inferência desejada. O conectivo1 está sendo utilizado no processo de agregação da regra e conectivo2 no processo de combinação das regras. A escolha do método para combinar os conjuntos associados às variáveis do sistema tem grande importância na estrutura do sistema. Na agregação, ou seja na composição dos vários conjuntos nebulosos de entrada dentro de uma regra, as t-normas min e produto são mais comuns, enquanto que na combinação ou composição das saídas nebulosas de cada regra, a s-norma max tem sido a mais utilizada na prática (SHAW e SIMÕES, 1999).

A parte da regra após o “SE” é a premissa (condição) ou antecedente da regra e a parte posterior ao “ENTÃO” é a sua conclusão (resultado ou ação) ou conseqüente (SHAW e SIMÕES, 1999). No caso de lógica binária, regras SE-ENTÃO não apresentam muita

dificuldade, pois se a premissa é verdadeira então a conclusão é verdadeira. Em regras nebulosas, se o antecedente possui algum grau de verdade então o consequente é também verdadeiro para o mesmo grau. Um sistema nebuloso contém muitas regras e todas são ativadas em paralelo, isto é, utilizam inferência associativa paralela, ao invés de em série como nos sistemas tradicionais. Neste caso, em um sistema nebuloso, a ordem de execução das regras não é importante, exceto quando uma regra depende dos resultados de execução de outras (KARTALOPOULOS,1996). Quando uma entrada é fornecida um sistema nebuloso dispara cada regra com graus diferentes, dependendo de um peso chamado de grau de suporte, que é um número no intervalo $[0,1]$ associado a cada regra, para inferir um resultado ou saída.

Existem dois tipos de sistemas de inferência que geralmente encontram-se implementados nos *softwares*: Mamdani e Sugeno. Estes dois tipos de sistemas de inferência variam um pouco na forma como são determinadas as saídas. Descrições destes dois tipos de sistemas de inferência podem encontrados nas referências MANDANI (1975) e SUGENO (1985).

2.3.6.1.3. Defuzzificação

A última etapa é a defuzzificação que consiste em obter a melhor representação para o conjunto de saída nebulosa, onde o valor da variável linguística de saída inferida pelas regras nebulosas será traduzido em um valor discreto. Pode-se dizer então que, a defuzzificação é o processo inverso da fuzzificação, transformando os valores nebulosos em *crisp*. Para selecionar o método apropriado de defuzzificação, pode-se utilizar um enfoque baseado no centro de área ou nos valores máximos que ocorrem da função de pertinência resultante. Os seguintes métodos são muito utilizados: média dos máximos (MoM), centro do máximo (CoM) e o centro de área (CoA) (SHAW E SIMÕES, 1999).

Uma abordagem para defuzzificação poderia ser a de se utilizar a saída com o maior valor de pertinência $\mu_{SAÍDA}(u_i)$. Em casos onde a função de pertinência tem mais de um máximo pode-se então utilizar a média de todos os máximos (SHAW E SIMÕES, 1999),

que é descrita pela seguinte equação:

$$MoM = \sum_{m=1}^M \frac{u_m}{M} \quad (2.25)$$

Onde u_m é o m-ésimo elemento no conjunto universo, onde a função $\mu_{SAÍDA}(u_i)$ tenha um máximo e M é o número total desses elementos. O termo $\mu_{SAÍDA}$ é composto pela união de todas as contribuições de regras. A abordagem média dos máximos é também chamada de solução mais plausível; por considerar o formato das funções de pertinência de saída.

O método centro de área é frequentemente chamado de método do centro de gravidade, pois ele calcula o centróide da área composta que representa o termo de saída nebulosa (SHAW E SIMÕES, 1999). Este método é calculado da seguinte forma:

$$CoA = \frac{\sum_{i=1}^N u_i \mu_{SAÍDA}(u_i)}{\sum_{i=1}^N \mu_{SAÍDA}(u_i)} \quad (2.26)$$

Onde $\mu_{SAÍDA}(u_i)$ é a área de uma função de pertinência modificada pelo resultado da inferência nebulosa e u_i é a posição do centróide da função de pertinência individual (SHAW E SIMÕES, 1999).

No método do centro do máximo, os picos das funções de pertinência representados no conjunto universo da variável de saída são usados, enquanto ignoram-se as áreas das funções de pertinência. Assumindo que os picos representam pesos, o valor de saída defuzzificado, discreto, é determinado encontrando-se o ponto de apoio onde os pesos ficam equilibrados (SHAW E SIMÕES, 1999). Assim, as áreas das funções de pertinência não desempenham nenhum papel e apenas os máximos (pertinências *singleton*) são usados. A saída discreta é calculada como uma média ponderada dos máximos, cujos pesos são os

resultados da inferência. O cálculo do valor defuzzificado é realizado através da equação (2.27), onde $\mu_{O,k}(u_i)$ indica os pontos em que ocorrem os máximos (alturas) das funções de pertinência de saída. Esse método também é chamado por método de defuzzificação pelas alturas.

$$CoM = \frac{\sum_{i=1}^N u_i \sum_{i=1}^N \mu_{O,k}(u_i)}{\sum_{i=1}^N \sum_{k=1}^n \mu_{O,k}(u_i)} \quad (2.27)$$

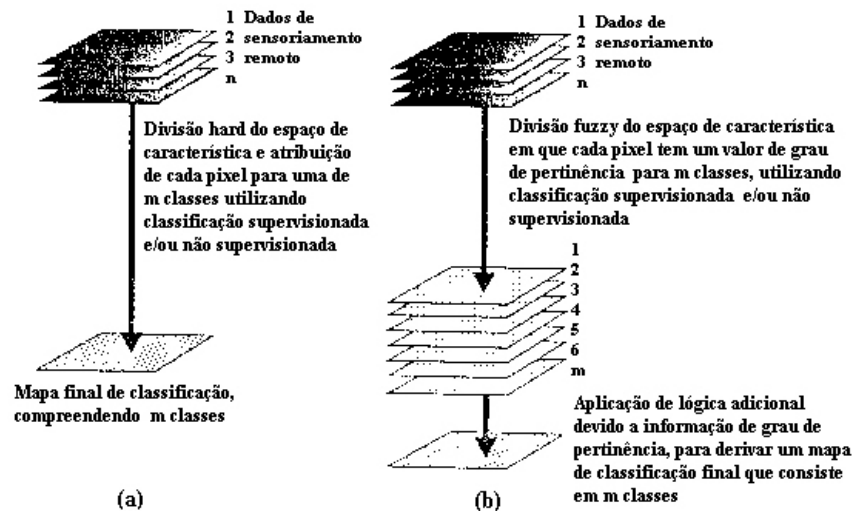
Como pode-se perceber as equações (2.26) e (2.27) são extremamente semelhantes, exceto pelo fato da equação (2.27) utilizar apenas seus máximos. Consequentemente, os resultados defuzzificados obtidos usando-se os dois métodos serão ligeiramente diferentes (SHAW E SIMÕES, 1999).

2.4. APLICAÇÃO DA TEORIA NEBULOSA A CLASSIFICAÇÃO DE IMAGENS

A teoria de conjuntos nebulosa considera a natureza heterogênea e imprecisa do mundo real e, pode ser utilizada juntamente com algoritmos de classificação supervisionada e não supervisionada (JENSEN, 1996). Através da teoria nebulosa as incertezas podem ser propagadas ao próximo nível lógico mais alto de um sistema que retém a informação, em vez de ser forçado a chegar prematuramente a uma decisão que é obrigatória em um sistema *hard* (CHENG et al., 2001). Devido a isto, a teoria nebulosa tem se destacado cada vez mais na área de processamento de imagens, pois proporciona uma ferramenta satisfatória na representação de incertezas que surgem em segmentação ou classificação, sendo possível através dela modelar a atividade de percepção dos seres humanos.

Na Figura 2.40 é apresentado um comparativo do processo de classificação de um *pixel* na classificação tradicional (*hard*) e na classificação utilizando lógica nebulosa.

FIGURA 2.40: REPRESENTAÇÃO DA CLASSIFICAÇÃO *HARD* E DA CLASSIFICAÇÃO UTILIZANDO LÓGICA NEBULOSA



FONTE: JENSEN, 1996

Na classificação nebulosa, o *pixel* tem m valores de graus de pertinência, determinando sua correlação com cada classe e, somente após este passo é que obtém-se o mapa temático, porém a classificação *hard* ignora a imprecisão encontrada no mundo real (JENSEN, 1996).

Nos métodos clássicos (máxima verossimilhança, distância mínima e método do paralelepípedo) considera-se o *pixel* como "puro" ou homogêneo, alocando-o a uma só classe, podendo acarretar perda de detalhes e a geração de uma imagem classificada incorreta (JENSEN, 1996). Com a utilização de sistemas nebulosos é possível implementar regras que considerem as incertezas da imagem em seu processamento. A maioria das pesquisas que se referem a classificação baseada em regras nebulosas utilizam métodos considerando as características espectrais. A seguir são apresentadas pesquisas que utilizaram sistemas baseado em regras nebulosas na classificação de imagens de sensoriamento remoto.

2.4.1. Sistema Nebuloso: *An Explicit Fuzzy Supervised Classification Method for Multispectral Remote Sensing Images*

a) Autor(es): MELGANI et al. (2000)

b) Imagem do satélite: Landsat TM

c) Bandas utilizadas: Azul (1), verde (2) e vermelho (3)

d) Classes de cobertura terrestre utilizadas: Áreas arenosas, terra agrícola, pastagem e solo exposto

e) Software utilizado: Linguagem C

f) Método utilizado na comparação: Máxima verossimilhança

g) Descrição: MELGANI et al. (2000) descreve um método de classificação supervisionada nebulosa para imagens multiespectrais. O método implementado pode ser descrito em três passos principais.

No primeiro passo geram-se variáveis nebulosas que compreendem as três bandas da imagem Landsat. Estas variáveis de entrada contemplarão quatro conjuntos nebulosos que correspondem as classes de cobertura: áreas arenosas, terra agrícola, pastagem e solo exposto. Nas funções de pertinência de cada conjunto nebuloso é utilizada a forma gaussiana e outra forma chamada de gaussiana modulada, com o objetivo de reduzir as sobreposições existentes entre as funções de pertinência geradas. Os parâmetros utilizados na geração destas funções são obtidos de extrações estatísticas das amostras selecionadas.

No segundo passo aplica-se uma regra de inferência nebulosa Min sobre as entradas nebulosas. Em seguida, nas saídas nebulosas deduzidas é aplicada uma operação de reamostragem utilizada para normalizar os valores deduzidos pela inferência. No último passo é efetuada a defuzzificação pelo operador Max resultando na imagem classificada.

Os resultados da classificação nebulosa foram comparados com o método da máxima verossimilhança, estando visualmente os dois resultados gráficos muito próximos. A classificação das amostras de treinamento revelou que o maxver é um pouco melhor que o método nebuloso com uma exatidão média de 79.52% contra 75.15% e uma exatidão global de 78.21% contra 77.38%. Porém, os resultados da classificação das amostras de teste apresentaram uma redução leve de quase 2% na exatidão para o método nebuloso (exatidão global de 75.54% e exatidão média de 74.71%) e uma redução de aproximadamente 5% na exatidão do maxver (exatidão global de 72.89% e exatidão média de 75.56%). O método nebuloso revelou menor tempo de classificação.

h) Análise do Método: Este método não apresentou resultados muito melhores que os obtidos pelo método da máxima verossimilhança. Isto se deve, provavelmente ao fato das funções de pertinência (classes) das variáveis de entrada (bandas) serem obtidas de parâmetros estatísticos dos dados de treinamento das amostras das bandas, onde mesmo utilizando-se a sugestão da forma gaussiana modulada são apresentadas muitas áreas com sobreposição de valores.

2.4.2. Sistema Nebuloso: *Fuzzy Rule-Based Classification of Remotely Sensed Imagery*

- a) Autor(es): BÁRDOSSY e SAMANIEGO (2002)
- b) Imagem do satélite: Landsat TM
- c) Bandas utilizadas: Azul(1), verde(2), vermelho(3), infravermelho próximo(4), infravermelho médio(5 e 7) e infravermelho termal(6)
- d) Classes de cobertura terrestre utilizadas: floresta, áreas permeáveis, áreas impermeáveis e corpos d'água
- e) Software Utilizado: Não informado
- f) Método Utilizado na Comparação: Máxima Verossimilhança
- g) Descrição: BÁRDOSSY e SAMANIEGO (2002) descreve um método de classificação supervisionada nebulosa para imagens multiespectrais. As variáveis nebulosas correspondem as sete bandas da imagem contendo funções de pertinência na forma triangular. As regras do sistema são derivadas das amostras das classes através da utilização de um algoritmo de otimização.

A partir do conjunto de treinamento foram geradas nove regras, sendo três para áreas permeáveis e duas regras para cada uma das demais classes de cobertura terrestre. No processo de inferência utilizou-se a operação de produto, sendo que as respostas nebulosas das diferentes regras foram combinadas usando um método aditivo e uma subseqüente defuzzificação usando a média nebulosa.

A execução do classificador gerou um mapa temático e uma imagem que descreve

o grau de ambigüidade de classificação para cada *pixel*. O resultado do classificador nebuloso teve a exatidão global de 98,7% e do maxver 98.3%, sendo considerado o nebuloso tão bom quanto o maxver, na realidade, ligeiramente melhor como a diferença é de aproximadamente 0.4%.

h) Análise do Método: Neste sistema através do algoritmo de otimização foram geradas as regras derivadas das amostras das classes sendo utilizados diversos conjuntos na forma triangular. O problema desta implementação em uma imagem Ikonos é o fato da mesma possuir somente quatro bandas multiespectrais, reduzindo drasticamente a separabilidade entre os diversos tipos de feições existentes. No experimento de BÁRDOSSY e SAMANIEGO (2002), nota-se que mesmo com a utilização das sete bandas do LandSat, o resultado obtido pelo método proposto e o maxver é praticamente o mesmo.

2.4.3. Sistema Nebuloso: *Fuzzy Logic System for Road Identification Using Ikonos Images*

a) Autor(es): AMINI et al. (2002)

b) Imagem do satélite: Ikonos

c) Bandas utilizadas: Não informado

d) Classes de cobertura terrestre utilizadas: Estradas principais e estradas de subúrbio

e) Software Utilizado: Visual C++

f) Método Utilizado na Comparação: Análise das estradas detectadas

g) Descrição: Neste estudo, um sistema de lógica nebulosa é utilizado para a detecção de estradas suburbanas. Inicialmente são geradas as variáveis de entrada chamadas de média e desvio padrão e variável de saída chamada nível de cinza. Os valores de médias e desvios padrão antes da fuzzificação são determinados através de duas etapas que utilizam o histograma da imagem.

Inicialmente efetua-se a suavização do histograma através de um filtro gaussiano.

A partir do histograma suavizado, objetos (regiões com propriedades semelhantes) são detectadas pela identificação dos pontos de pico e de vale (máximos e mínimos). Para definir os pontos de pico e vale do histograma, utilizam-se dois passos. Aplica-se uma máscara $-1/1$ no histograma suavizado gerando a primeira derivada. No resultado gerado é aplicada novamente a máscara $-1/1$ indicando a segunda derivada.

Pelas regras seguintes os picos e vales são detectados: a) se a segunda derivada for maior que zero e a primeira derivada igual a zero, então o ponto é um vale (mínimo) ou b) se a segunda derivada for menor que zero e a primeira derivada igual a zero, então o ponto é um pico (máximo).

Depois, são identificados os objetos a partir de um ponto de pico e seus dois pontos de vale à esquerda e à direita, utilizando uma margem de segurança de 0.1 para separar cada objeto. A média e o desvio padrão de cada objeto são calculadas e usados como os valores das variáveis de entrada. Estas variáveis abrangerão cinco conjuntos nebulosos chamados de abaixo-ruim, abaixo-prov-bom, bom, acima-prov-bom e acima-ruim com funções de pertinência gaussiana. Em seguida, efetua-se a inferência nebulosa que avalia o conjunto de regras que definem o procedimento do sistema sendo na defuzzificação utilizado o método do centro dos máximos.

Para avaliar o sucesso do algoritmo, foram considerados dois tipos de estradas na imagem original: estradas principais com uma largura de 6 a 12 pixels e outras estradas com uma largura de 3 a 5 pixels. Estas estradas foram extraídas manualmente e automaticamente de forma que a precisão da imagem poderia ser avaliada. Os testes apresentados indicam que considerável sucesso foi alcançado com o algoritmo, particularmente para estradas principais mostradas em imagens de satélite de alta resolução.

h) Análise do Método: O artigo de AMINI et al (2002) cita um método de detecção de objetos, onde seus níveis de cinza são utilizados nas variáveis de entrada nebulosas. Depois, geram-se as regras para identificar quais intervalos de cinza correspondem à estrada.

Para avaliar o desempenho deste método, foram efetuados diversos testes com a imagem multiespectral (Banda 1) e pancromática do Ikonos com e sem a suavização pelo

filtro gaussiano (3x3) e desvio padrão (de 0.3 a 0.5). Utilizando as imagens do Ikonos e inclusive uma imagem do Landsat, verificou-se nos testes que não foi possível detectar os objetos. Nas imagens do Ikonos foram detectados diversos vales, mas nenhum pico e, na imagem Landsat não foi possível detectar os objetos, pois não ocorreu um número suficiente de vales. As regras para detecção de picos e vales (citadas no artigo) referente a primeira e segunda derivada estão corretas, o que indica que a máscara sugerida não se adapta a qualquer tipo de imagem

Ainda buscando a idéia básica de AMINI et al. (2002) com relação à detecção de objetos, optou-se pela utilização da transformação *tophat* (FACON, 1996) de forma a implementá-la em substituição ao método de detecção de objetos utilizado. Foram efetuados os seguintes passos:

- a) Seleção das amostras da classe Estrada na imagem;
- b) Suavização da imagem aplicando um filtro gaussiano (3x3);
- c) Cálculo da média e desvio padrão das amostras;
- d) Geração do histograma;
- c) Execução da transformação *tophat* por abertura para detectar os picos;
- d) Execução da transformação *tophat* por fechamento para detectar os vales;
- e) Exclusão de picos seguidos de picos e vales seguidos de vales, verificando no histograma (se pico: qual o que possui maior frequência e se vale: qual o que possui menor frequência);
- f) Geração de objetos sendo definidos através do vale direito, pico e vale esquerdo;
- g) Agrupamento dos vários objetos detectados através da utilização dos limiares: média + desvio padrão e média - desvio padrão;
- h) Segmentação binária utilizando os intervalos dos objetos que estão dentro do limiar.

Este processo foi aplicado sobre as imagens nas bandas multiespectrais (1,2,3). Os passos g e h foram efetuados devido a grande quantidade de objetos (entre 67 e 72) gerados quando utilizado somente o método *tophat*.

Mas, mesmo utilizando esta implementação não houve sucesso, devido à imagem binária gerada nem sempre refletir a cobertura terrestre desejada. Face a estes testes, concluiu-se que, possivelmente as amostras de estrada utilizadas por AMINI et al. (2002) abrangeram um intervalo de níveis de cinza menor, com pouca variação espectral na classe, diferentemente dos tipos de estrada (terra, ferro, asfalto) existentes na imagem utilizada neste experimento. Portanto, verifica-se que este método não se adapta a qualquer tipo de cena.

2.4.4. Sistema Nebuloso: *A Fuzzy Classification Approach for High-Resolution Multispectral Data Over Urban Areas*

- a) Autor(es): SHACKELFORD e DAVIS (2002)
- b) Imagem do satélite: Ikonos
- c) Bandas utilizadas: Pancromática e multiespectrais (1, 2, 3 e 4)
- d) Classes de cobertura terrestre utilizadas: estrada, construção, água, solo exposto, sombra, grama e árvore
- e) Software Utilizado: Não informado
- f) Método Utilizado na Comparação: Máxima Verossimilhança
- g) Descrição: Este estudo apresenta uma técnica de classificação nebulosa que combina características espectrais e espaciais extraídas dos dados, com o intuito de reduzir erros de classificação em classes espectralmente semelhantes como grama/árvore e estrada/edificações.

Primeiramente é efetuada uma fusão da banda pancromática com as bandas multiespectrais, gerando-se quatro imagens com 1 metro de resolução espacial. Pelos experimentos analisados, a característica mais apropriada para diferenciar entre grama e árvore foi a medida de textura entropia com janela 10x10 e a característica mais apropriada para diferenciar entre estrada e construção foi a característica contextual de comprimento e largura de grupos espectralmente semelhantes de pixels conectados. As características de textura e contextual foram extraídas da banda pancromática. Porém, enquanto uma

característica espacial pode aumentar a precisão de classificação entre um conjunto de classes, ela pode reduzir a precisão entre outro conjunto.

Para que classes diferentes fossem classificadas utilizando somente as características mais apropriadas para as mesmas, um esquema de classificação nebulosa foi implementado permitindo que os dados fossem hierarquicamente classificados usando diferentes características espaciais para diferentes conjuntos de classes. Inicialmente utilizou-se o método da máxima verossimilhança para dividir os dados dentro de dois conjuntos: vegetação (grama e árvore) e não-vegetação (estrada, construção, água, solo exposto e sombra). Então, utilizando-se as quatro bandas espectrais obtidas da fusão mais a característica espacial apropriada, geraram-se os conjuntos nebulosos na forma gaussiana calculados para cada classe a partir dos dados de treinamento. A classificação *crisp* final é gerada pela utilização do operador de união nebuloso (max).

A exatidão global da classificação teve um aumento de 7% em relação ao resultado obtido pela classificação de máxima verossimilhança, reduzindo o número de classificações incorretas entre as classes de estrada/construção e grama/árvore. As classes de estrada, construção, árvore e grama, tiveram respectivamente um aumento de 10%, 2%, 11% e 13% em relação ao resultado obtido pela classificação de máxima verossimilhança, resultando em exatidão média de 76.2% para estrada e construção e de 97.5% para árvore e grama.

h) Análise do Método: Em SHACKELFORD e DAVIS (2002) é apresentado um método que possui quatro passos de implementação:

- a) fusão das imagens pancromática e multiespectral;
- b) aplicação da textura;
- c) algoritmo para detecção da largura e comprimento, de forma a detectar ruas e edificações;
- d) implementação das regras nebulosas combinando as informações anteriores.

O desenvolvimento do algoritmo utilizado para detectar as estradas não foi efetuado, pois os valores desta classe na imagem utilizada neste trabalho possuem grande variação espectral, devido a abranger diversos tipos de materiais como: terra, asfalto,

paralelepípedo, entre outros.

Neste caso, de forma a efetuar a análise do experimento, foram efetuados testes utilizando a fusão pelo método dos Componentes Principais. A medida de textura utilizada foi entropia com janela 9x9 aplicada na imagem híbrida, mas não gerou resultados satisfatórios de forma a distinguir entre vegetação rasteira e arbórea. Como forma alternativa para verificar o desempenho da aplicação da textura, analisou-se também o trabalho de ZHANG (2001).

Embora não utilize regras nebulosas, ZHANG (2001) também executa experimentos que utilizam medidas de textura, com o objetivo de diferenciar floresta e grama. O método implementado utiliza medidas de textura para distinguir áreas homogêneas de heterogêneas, detectando árvores ao executar o processo na banda infravermelho, azul e verde. No artigo são efetuados testes com diversos métodos de textura, apresentando os resultados da aplicação dos mesmos e propondo um novo processo chamado detecção de variância condicional. Este método divide-se em dois passos chamados: variância direcional e variância local.

No passo da variância direcional é efetuado o cálculo do valor médio da diferença absoluta dos *pixels* vizinhos em cada uma das quatro direções. Quando o valor da variância de um dos quatro lados é menor que um determinado limiar, conclui-se que este determinado lado está localizado em uma área homogênea e portanto, o *pixel* central da máscara será considerado como pertencente a uma área homogênea, isto é "não árvore", atribuindo-se a ele o valor 0.

No passo seguinte, aplica-se a variância local em cada posição da imagem resultante do primeiro passo que possui o valor 1, ou seja, área heterogênea que possui árvore. Neste caso, se o valor da variância local estiver acima de um determinado limiar, indica-se que o *pixel* pertence a árvore. Ao final do processo, a parte clara da imagem resultante deve apresentar as áreas que possuem árvores. ZHANG (2001) comenta que utilizou na variância direcional máscara 9x9 e na variância local máscara 3x3, porém informa que tanto os limiares quanto as máscaras devem ser decididos de acordo com a resolução das imagens e relacionamento entre árvores e construções.

Com base no experimento de ZHANG (2001) foram efetuados testes na imagem Ikonos utilizando diversos tamanhos de máscara (variância direcional: 5x5, 7x7, 9x9 e variância local: 3x3) e valores de limiar, provenientes da média e desvio padrão das amostras nas bandas 1, 2, 3 e 4 e na pancromática. Porém, os resultados não foram satisfatórios, havendo dificuldades na detecção do melhor limiar, isto se deve, provavelmente ao fato da imagem utilizada por ZHANG (2001) possuir uma resolução melhor do que a utilizada neste estudo.

Os artigos descritos acima retratam bons resultados da classificação utilizando um sistema nebuloso com relação aos métodos tradicionais como o maxver. Porém, pela análise efetuada, observa-se que não é possível obter bons resultados ao aplicá-los na imagem Ikonos utilizada neste estudo, devido aos diferentes tipos de feições existentes em uma imagem. Assim, há a necessidade da implementação de novos métodos que visem classificar de forma mais acurada a imagem.

Através da utilização de sistemas nebulosos várias imagens de referência que ressaltam determinadas feições podem ser combinadas, gerando a classificação. Face a isto definiu-se e implementou-se um novo método de classificação neste trabalho.

Pelas pesquisas analisadas, observa-se que a maioria dos sistemas de classificação supervisionada baseada em regras nebulosas são realizadas considerando as características espectrais das imagens, nas quais as variáveis de entrada nebulosas correspondem as bandas da imagem e suas funções de pertinência correspondem as classes que busca-se detectar. Os parâmetros dos conjuntos de pertinência são gerados de valores estatísticos das amostras de treinamento da classe em determinada banda, como descrito em MELGANI et al. (2000) e BÁRDOSSY e SAMANIEGO (2002).

Na abordagem proposta, desenvolve-se uma nova técnica de classificação supervisionada que abrange regras nebulosas considerando as características espectrais. Porém, o diferencial deste sistema consiste no processo de criação das variáveis de entrada, as quais não correspondem as bandas da imagem, sendo geradas de imagens de referência

(índices). Os parâmetros para gerar estas variáveis são obtidos das amostras das imagens razão (*ratio images*) que visam destacar determinadas feições. As variáveis são combinadas através das regras nebulosas, definindo para cada classe as características mais adequadas para distinguí-las. Este novo método é descrito de forma detalhada nos itens seguintes.

3. METODOLOGIA


3.1. MATERIAIS E INFRA-ESTRUTURA

3.1.1. Área de Estudo

3.1.1.1. Localização

A área de estudo compreende parte das cidades de Rio Negro no Paraná (Figura 3.1) e Mafra em Santa Catarina (Figura 3.2), localizada à aproximadamente 104 km de Curitiba.

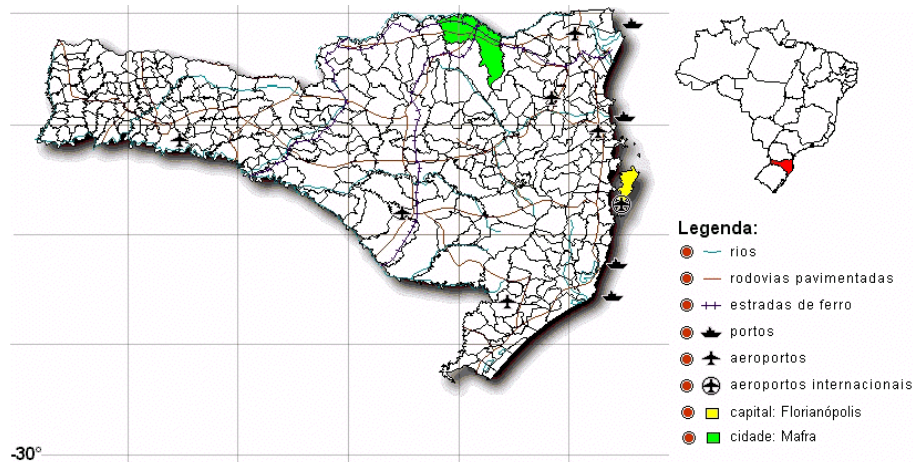
FIGURA 3.1 – MAPA DE LOCALIZAÇÃO DA CIDADE DE RIO NEGRO NO PARANÁ



O município de Rio Negro foi fundado em 1870, estando a uma altitude de aproximadamente 780m. (CITYBRAZIL, 2003). Segundo o censo de 2000 possui uma área total de 603,42 km² e aproximadamente 28.710 habitantes (IBGE, 2003). O município de Mafra foi fundado em 1917, estando a uma altitude de aproximadamente 793m. (CITYBRAZIL, 2003). Segundo o censo de 2000 possui uma área total de 1.784,84 km² e

aproximadamente 49.940 habitantes (IBGE, 2003).

FIGURA 3.2 – MAPA DE LOCALIZAÇÃO DA CIDADE DE MAFRA EM SANTA CATARINA



3.1.1.2. Características

A maior parte da vegetação presente na região da imagem abrange a formação denominada floresta ombrófila mista, também conhecida como floresta com araucária. Mas, em certos locais da imagem (Figura 3.3) existem algumas peculiaridades descritas a seguir.

a) Na Figura 3.3 (cor rosa), encontra-se uma formação vegetal primária, porém alterada que abrange mata ripária (ciliar) típica de regiões frequentemente alagáveis, com vegetação mais baixa e predomínio do branquilha, além de gramíneas.

b) Na Figura 3.3 (cor azul) é encontrada mata ciliar menos suscetível a inundações, com vegetação mais alta, ocorrendo espécies como a guavirova, cambuís e branquinhos, que correspondem a uma formação primária com alterações. Adentrando para o interior, em direção à casa de formação, aparecem outra espécies típicas da formação de floresta ombrófila mista:

c) Na Figura 3.3 (cor amarela) predomina floresta primária alterada, com mesclas de formações secundárias em fase média e avançada de regeneração. Ocorrem nessa região

espécies como: araucária, imbuia, canela, erva-mate, guavirova, pinho-bravo, guamirins, cambuís, pitanga, entre outras típicas. Esta formação vegetal é importante pelo fato de possuir espécies típicas que correm risco de extinção, como é o caso da imbuia e da araucária, além do fato da maior parte das espécies produzirem frutos que são avidamente devorados pela avifauna, havendo grande incidência da mesma na região, que por sua vez, também colabora com a disseminação das espécies vegetais.

As áreas mais claras na vegetação são áreas de desmate e as mesclas de vegetação escura na região urbanizada são pequenos remanescentes da antiga floresta ou bosques. O clima da região é temperado, com verões frescos e sem estação seca definida.


Esta área da imagem (Figura 3.3) foi escolhida, pois apresenta distintos tipos de cobertura de solo, permitindo uma melhor avaliação do método de classificação implementado. A dimensão da imagem utilizada no experimento é 500x900, contemplando as bandas multiespectrais do visível (azul, verde e vermelha) e do infravermelho próximo, obtidas a partir do sensor do satélite IKONOS no ano 2000, conforme apresentado na Figura 3.3. Como pode ser observado, devido à alta resolução da imagem do IKONOS, é possível visualizar feições de tamanho menor, como por exemplo, as pequenas edificações presentes nas paisagens urbanas. Alguns pontos de referência foram identificados na imagem, conforme apresentado na legenda.

3.1.2. Hardware e Software

A configuração do *hardware* utilizado no processamento das informações foi um computador com processador Pentium III - 600Mhz e 192Mbytes de memória RAM, com sistema operacional Windows Millenium.

No desenvolvimento do trabalho foram utilizados os *softwares* MultiSpec e MATLAB 6.0.

FIGURA 3.3 – IMAGEM MULTIESPECTRAL UTILIZADA NA CLASSIFICAÇÃO

**LEGENDA:****VEGETAÇÃO:**

- Mata ciliar menos suscetível a inundações
- Mata ripária (ciliar) típica de regiões frequentemente alagáveis
- Floresta primária alterada

PONTOS DE REFERÊNCIA:

- Rio Negro
- Casa de Formação da Igreja Católica
- Estação de Tratamento de Esgoto (ETE)
- Vila Solidariedade (Mafra)
- CAIC (Mafra)
- Antiga Fábrica de Esquadrias de Madeira
- Estrada de ferro (América Latina Logística)
- Estádio Municipal
- Casa da Criança e do Adolescente
- Estrada de Acesso Parque S.Luis de Tolosa/ Prefeitura Rio Negro

3.1.2.1. *Software* MultiSpec

MultiSpec é um *software* utilizado na análise de imagens multispectrais, tendo sido desenvolvido especificamente para a manipulação de imagens de sensoriamento remoto, sendo de fácil aprendizagem e uso, devido à simplicidade do programa.

O propósito original do MultiSpec (desenvolvido pela Universidade de Purdue) era prover uma ferramenta fácil de usar que poderia ser utilizada na pesquisa pedagógica, mas especialmente, provendo a habilidade para pesquisadores estudarem e desenvolverem

algoritmos e técnicas novas sem ter que programar os algoritmos já existentes, devido aos mesmos já estarem previamente desenvolvidos. A versão atual do MultiSpec foi implementada para estações de trabalho com a plataforma Macintosh ou Windows e pode ser usada para exibir e analisar dados com mais de 200 bandas espectrais. O MultiSpec está em constante pesquisa pela Fundação de Pesquisa Purdue sendo frequentemente acrescentadas novas funcionalidades (BIEHL e LANDGREBE, 2002).

Tendo em vista que os resultados do método proposto foram comparados com os resultados obtidos pelos métodos da máxima verossimilhança (MaxVer) e Isodata tornou-se conveniente a escolha do software MultiSpec, devido ao mesmo já possuir os dois métodos implementados, visando a praticidade do processo, já que não havia a necessidade de desenvolver programas com esta implementação. Algumas das funcionalidades do *software* utilizadas neste estudo foram as seguintes:

- a) Exibir as bandas das imagens multispectrais simultaneamente, permitindo que se selecione o canal RGB desejado para cada banda, de forma a analisar os detalhes da imagem;
- b) Reformatar os dados do arquivo de imagens podendo efetuar a separação das bandas em arquivos distintos. Desta forma, foi possível efetuar a leitura da imagem em seu formato original, separando as 04 bandas multispectrais em 04 arquivos distintos, permitindo que os mesmos pudessem ser lidos pelo software MATLAB;
- c) Verificar a separabilidade dos diversos tipos de cobertura de solo através da execução do algoritmo de agrupamento Isodata, gerando os resultados como um mapa temático, sendo permitida a alteração da cor utilizada para cada tema;
- d) Definir as amostras de classes através do delineamento das diversas áreas de interesse utilizando a forma retangular;
- e) Analisar o subconjunto de características espectrais de cada classe que serão utilizadas na classificação através da medida de distância estatística da divergência transformada entre as classes;
- f) Comparar o resultado gerado pelo método de classificação proposto com o método da máxima verossimilhança. Neste software, é possível gerar a classificação através

do algoritmo da máxima verossimilhança, podendo-se testar as amostras de classes previamente selecionadas, listando seus resultados de classificação de treinamento na forma tabular. No caso do mapa temático gerado pode-se alterar a cor utilizada para cada tema.

3.1.2.2. *Software* MATLAB

Para atender aos requisitos necessários na execução dos experimentos, devido a proposta de implementação de um sistema baseado em regras nebulosas, foi escolhido o software MATLAB 6.0, por possuir funcionalidades específicas para este fim, além de funções para manipulação das imagens.

O MATLAB (*MATrix LABoratory*) é um ambiente de computação técnico-científica para desenvolvimento de sistemas sofisticados e eficientes. Ele integra computação, visualização e programação dentro de um ambiente interativo de fácil aprendizado e uso. Como um ambiente de programação, o MATLAB possui seu próprio editor de programas, simplificando bastante o seu uso e, seus programas são escritos e gravados em arquivos, chamados *scriptfiles*, cujos nomes possuem extensão “.m”. Depois de criar um arquivo nome.m, o mesmo pode ser executado como qualquer outro comando ou função do MATLAB. Não é necessário compilar o programa uma vez se trata de uma linguagem interpretada.

O *software* MATLAB permite visualizar 3 bandas das imagens em composição RGB, pois não é um software específico para área de sensoriamento remoto. Utilizações típicas deste *software* incluem: matemática e computação; desenvolvimento de algoritmos; aquisição de dados; modelagem, simulação e prototipação; análise de dados, exploração e visualização; geração de gráficos e desenvolvimento de aplicações, incluindo a construção da interface gráfica para o usuário (MATSUMOTO, 2002). O nome MATLAB refere-se a laboratório de matriz, pois foi escrito originalmente para prover acesso fácil a *softwares* desenvolvidos para manipulação de matrizes.

Desde a sua primeira versão (1984), o MATLAB vem sendo utilizado por

estudantes, professores, pesquisadores, cientistas, engenheiros e profissionais de tecnologia de informação como ferramenta para criação, análise e simulação de modelos matemáticos aplicados às mais diversas áreas, desde a automação e controle industrial até gerenciamento de risco financeiro. Este *software* possui versões para diferentes ambientes operacionais como: Windows 98/ME/XP, Linux, Unix e Macintosh (MATSUMOTO, 2002).

A empresa The Mathworks (que distribui as versões do MATLAB) com o apoio de consultorias especializadas, desenvolve e comercializa bibliotecas de funções de MATLAB (m-files), denominadas *toolbox*, aplicadas a áreas específicas como estatística, processamento de imagens, lógica nebulosa, redes neurais, totalizando mais de 60 títulos diferentes. Estas caixas de ferramentas permitem ao usuário aprender e aplicar tecnologia especializada para resolver problemas específicos. Neste estudo, as mais utilizadas foram a *toolbox* de processamento de imagens e de lógica nebulosa.

A *toolbox* de processamento de imagens estende o ambiente computacional do MATLAB para prover funções e ferramentas interativas para analisar e melhorar as imagens digitais e desenvolver algoritmos de processamento de imagens. Juntos, MATLAB e o *toolbox* de processamento de imagens provêm a cientistas, pesquisadores e engenheiros de áreas diversas, um conjunto flexível de ferramentas para resolver problemas complexos de imagem dentro de disciplinas como: defesa e espaço aéreo; astronomia, sensoriamento remoto, imagem científica e médica e ciência de materiais.

A *toolbox* de lógica nebulosa é uma coleção de funções construídas no ambiente computacional do MATLAB que provê ferramentas para criar e editar sistemas de inferência nebulosa dentro da estrutura do MATLAB ou integrar os sistemas nebulosos em simulações por meio do *simulink* ou até mesmo construir programas C que chamam os sistemas nebulosos que foram construídos. Esta *toolbox* possui uma interface gráfica que auxilia na realização do trabalho, embora permita que se trabalhe apenas com as funções de linha de comando.

3.1.3. Técnicas Utilizadas

3.1.3.1. ISODATA

Para a identificação dos diversos tipos de cobertura terrestre, é adequado avaliar a separabilidade das classes que serão utilizadas: água, vegetação rasteira; vegetação arbórea, edificações e estrada. Este tipo de análise pode ser efetuado ao aplicar sobre a imagem um algoritmo de segmentação. Neste caso, todos os *pixels* que possuem semelhança espectral serão associadas a determinado agrupamento, sendo possível verificar se estes agrupamentos espectrais correspondem realmente às classes de cobertura que procura-se classificar. A vantagem deste tipo de segmentação é que a imagem temática resultante pode ser avaliada e manipulada antes de se proceder a uma classificação supervisionada, permitindo avaliar a potencialidade de discriminação de classes espectrais de uma determinada imagem.

Para analisar a separabilidade das classes, foi efetuada a classificação não supervisionada pela aplicação do algoritmo de agrupamento Isodata na imagem. Na execução do método foram utilizados os seguintes parâmetros: de 5 a 10 *clusters* distintos de classes, convergência de 98%; um total de 100 iterações e *clusters* contendo no mínimo 5 *pixels*.

Na Tabela 3.1 são descritos os tipos de feições terrestres que foram observados na análise visual dos *clusters* obtidos pela classificação Isodata.

Nas Figura 3.4 e 3.5, pode-se verificar que:

- Os valores baixos de *pixel* da estrada de ferro e da vegetação arbórea acarretaram o agrupamento destas junto a água;
- As estradas de asfalto foram melhor detectadas com 05 *clusters*. Mas, devido a diversidade de materiais da estrada (como por exemplo terra) e das telhas (eternit, cerâmica, barro), não houve boa separabilidade entre as edificações e estrada.
- As estradas de terra e solo exposto também não foram bem identificadas devido a semelhança espectral existente entre elas onde predominam valores altos de *pixel*.

Observando os tipos de cobertura detectados pelos *clusters* (apresentados na Tabela

3.1 e Figuras 3.4, 3.5 e 3.6), nota-se que os resultados não foram significativos, visto que há grande semelhança espectral entre as classes: estrada/água, vegetação arbórea/água, edificações/estrada e solo exposto/estrada.

TABELA 3.1 – CLASSES ESPECTRAIS DETECTADAS COM O MÉTODO ISODATA

CLASSES ESPECTRAIS DETECTADAS COM A APLICAÇÃO DO MÉTODO ISODATA						
Número do Cluster	Total de Clusters Gerados pelo Método					
	5	6	7	8	9	10
1 (Azul)	Água, grande parte da vegetação arbórea e estrada de ferro.	Idem Anterior	Idem Anterior	Água, porções de vegetação arbórea e de estrada de ferro.	Idem Anterior	Idem Anterior
2 (Vermelho)	Grande parte das edificações e solo exposto, abrangendo também estradas de terra.	Grande parte das estradas (asfalto e terra), edificações e pequenas porções de solo exposto e vegetação rasteira.	Idem Anterior	Idem Anterior	Porções das estradas (asfalto e paralelepípedo), edificações e solo exposto.	Porções das estradas (asfalto, e paralelepípedo e terra), edificações e solo exposto.
3 (Preto)	Parte das estradas (asfalto, paralelepípedo e pedra), edificações e pequenas porções de solo exposto.	Pequena porções das estradas (paralelepípedo, pedra, asfalto, linha férrea), edificações e solo exposto.	Idem Anterior	Idem Anterior	Idem Anterior	Grande parte da estrada de ferro e pequenas porções de asfalto, solo exposto e edificações.
4 (Verde Claro)	Vegetação rasteira com pequenas porções de solo exposto.	Idem Anterior	Idem Anterior.	Idem Anterior	Idem Anterior	Parte da vegetação rasteira.
5 (Verde Escuro)	Pequenas porções da vegetação arbórea da cena e de solo exposto.	Porções da vegetação arbórea da cena.	Idem Anterior	Idem Anterior	Pequenas porções de vegetação arbórea onde predominam sombras.	Idem Anterior
6 (Rosa)		Algumas edificações com telha de eternit, parte das estradas de terra e solo exposto.	Algumas edificações com telha de eternit.	Idem Anterior	Idem Anterior	Idem Anterior
7 (Amarelo)			Parte das edificações, estradas (terra e asfalto), solo exposto e vegetação rasteira.	Idem Anterior	Algumas edificações (telha eternit) e porções de estradas (terra) e solo exposto..	Idem Anterior
8 (Verde Médio)				Grande parte da vegetação arbórea.	Idem Anterior	Parte da vegetação arbórea e rasteira.
9 (Cinza)					Parte das edificações, estradas (terra e asfalto) e vegetação rasteira.	Parte das edificações, estradas (terra) , solo exposto e vegetação rasteira
10 (Azul Claro)						Parte da vegetação arbórea.

FIGURA 3.4 – CLASSIFICAÇÃO DO ISODATA – ÁREA 01

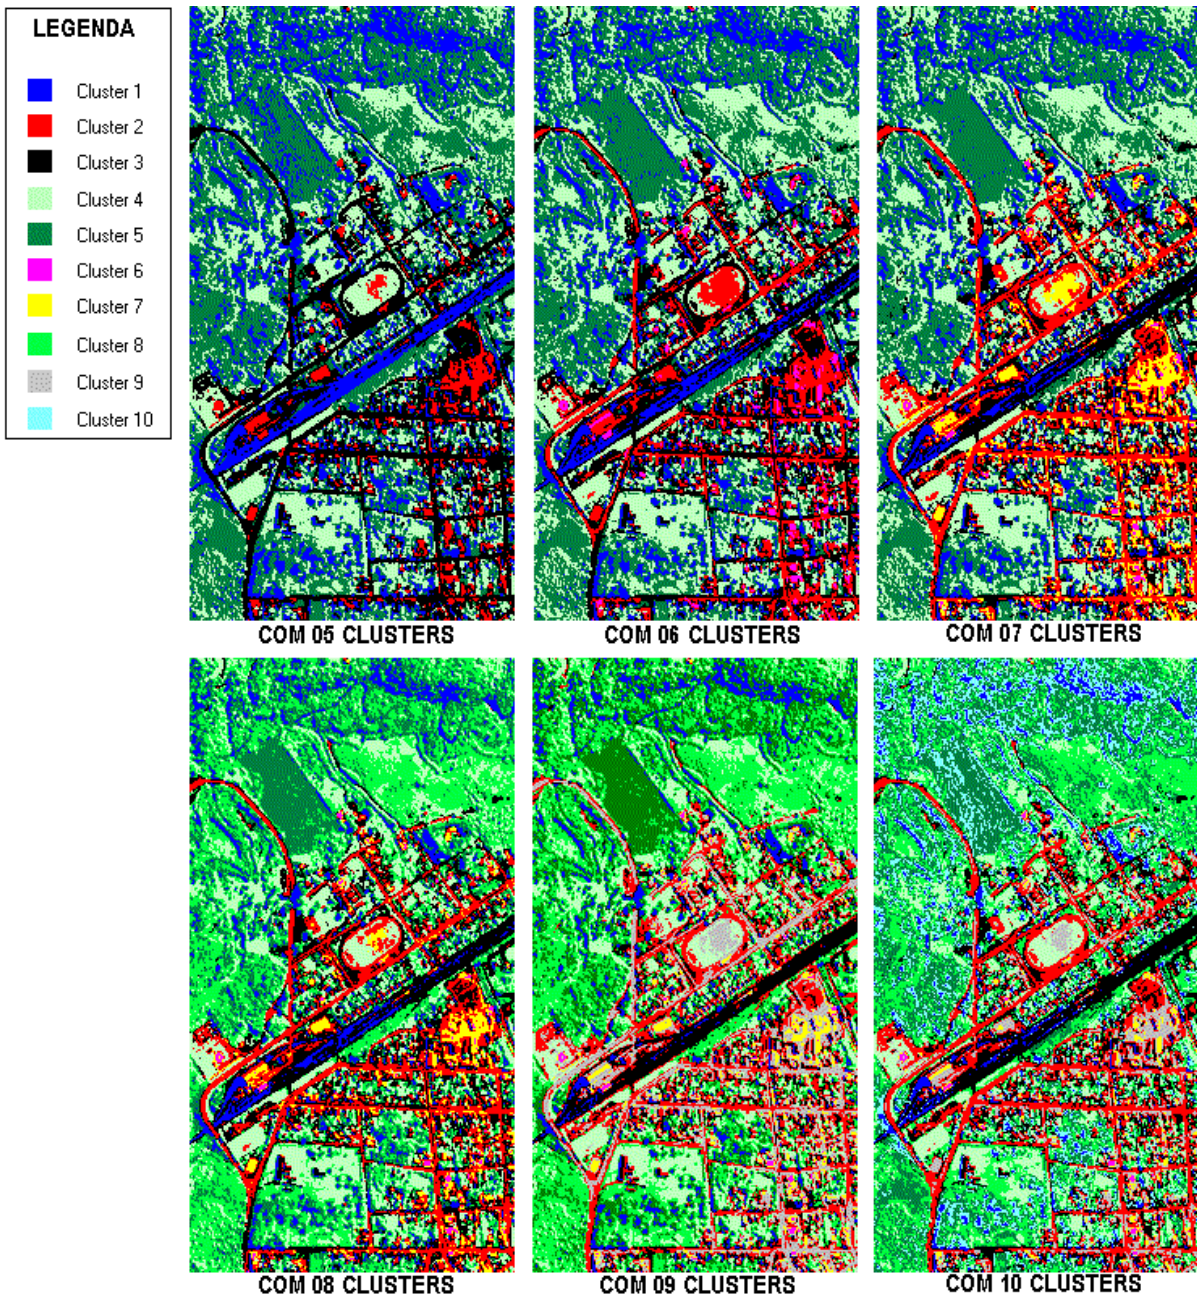


FIGURA 3.5 – CLASSIFICAÇÃO DO ISODATA – ÁREA 02

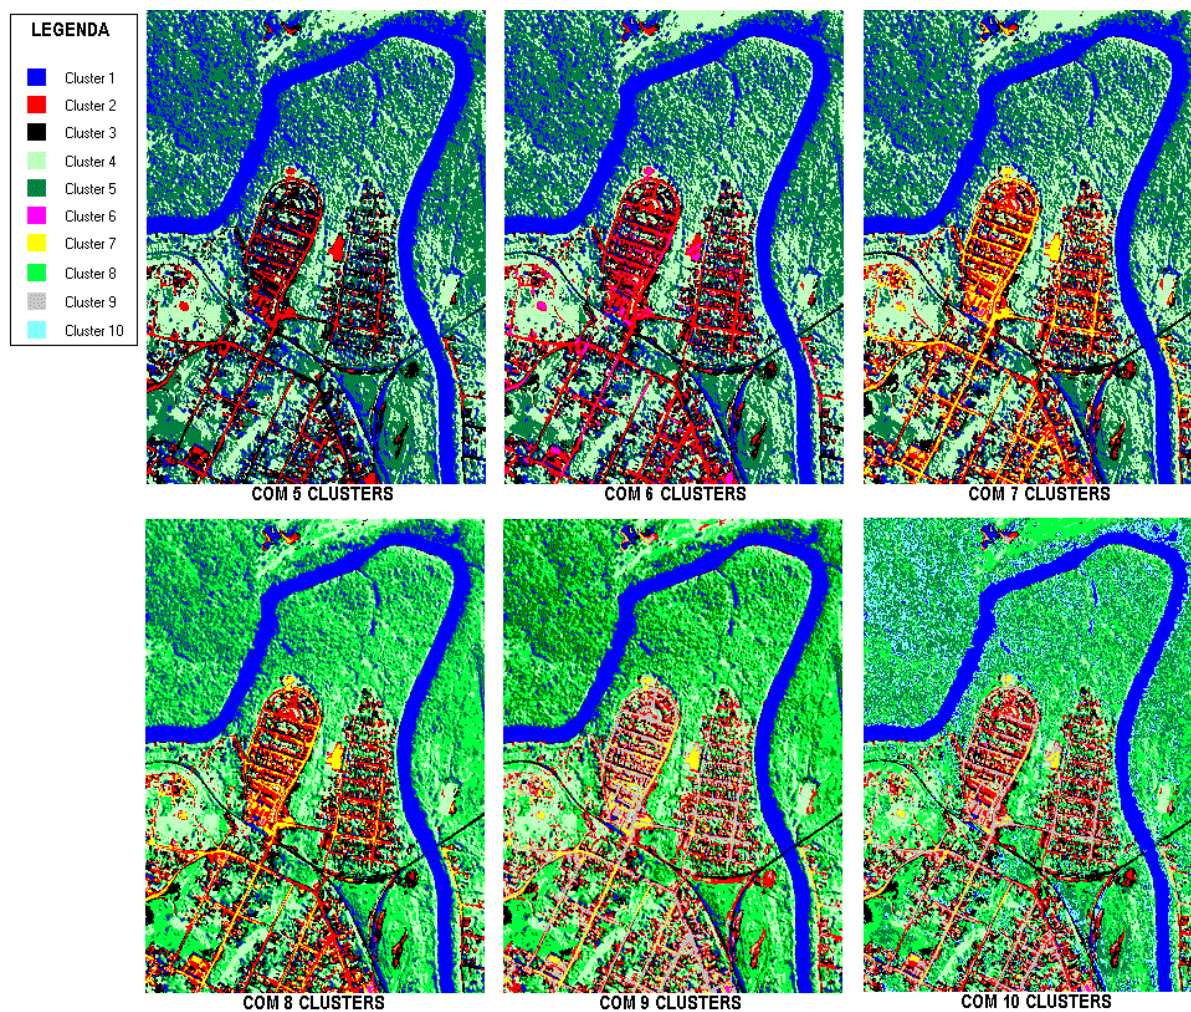



FIGURA 3.6 – CLASSIFICAÇÃO DO ISODATA COM 5 CLUSTERS



3.1.3.2. Máxima Verossimilhança

Nos artigos analisados (MELGANI et al., 2000; BÁRDOSSY e SAMANIEGO, 2002; SHACKELFORD e DAVIS, 2002) foi utilizada a classificação supervisionada pelo método da máxima verossimilhança para propósitos de comparação. Desta forma, neste trabalho, o método proposto também será comparado pelo maxver, embora esta técnica seja geralmente aplicada na classificação de imagens de média resolução espacial.

Para gerar a classificação pelo método supervisionado da máxima verossimilhança (MaxVer) foram selecionadas 20 amostras de cada classe de cobertura que corresponde a: (água, vegetação rasteira, vegetação arbórea, edificações, estrada e solo exposto) contendo 06 *pixels*, totalizando 720 *pixels*.

Para garantir que as amostras de treinamento selecionadas representassem da melhor forma as classes a serem identificadas, foram selecionados *pixels*, analisando se os mesmos eram estatisticamente separáveis, através da avaliação do resultado gerado pela classificação das mesmas, sempre alterando ou inserindo novas amostras se necessário o fosse. Um dos métodos estatísticos de avaliação de separabilidade entre classes consiste em quantificar a possibilidade de discriminação entre diversas categorias aplicando uma medida de distância estatística entre duas classes. Neste estudo, foi utilizada a divergência transformada, onde os valores gerados mantêm-se em intervalos de 0 a 2000. Quanto maior for o valor da divergência (mais próximo a 2000) melhor será a discriminação entre as classes.

O método da divergência transformada indica qual a melhor combinação de bandas da imagem para discriminar as classes. Deste experimento resultou como melhor combinação a utilização de todas as bandas (1, 2, 3 e 4), conforme apresentado na Tabela 3.2.

Analisando os resultados numéricos da Tabela 3.2, nota-se que a separabilidade média resultou em 1985 e a separabilidade mínima em 1807, porém verifica-se que na maioria das relações entre classes, alcança-se o valor numérico de 2000, indicando boa separabilidade entre as classes. Os únicos valores em conflito são observados entre as classes que pertencem a grama/solo exposto (1974) e estrada/edificações (1807), este último retratando maior

dificuldade na separação das mesmas.

TABELA 3.2 – RESULTADO DA DIVERGÊNCIA TRANSFORMADA

Divergência Transformada para as Bandas 1,2,3 e 4	
Pares de Classes	Divergência Transformada
Floresta/Grama	2000
Floresta/Água	2000
Floresta/Estrada	2000
Floresta/Edificações	2000
Floresta/SoloExposto	2000
Grama/Água	2000
Grama/Estrada	2000
Grama/Edificações	2000
Grama/SoloExposto	1974
Água/Estrada	2000
Água/Edificações	2000
Água/Solo Exposto	2000
Estrada/Edificações	1807
Estrada/Solo Exposto	2000
Edificações/Solo Exposto	2000
Pior Separabilidade: 1807 e Separabilidade Média: 1985	

Existem várias formas de se avaliar a qualidade das amostras coletadas. Geralmente a qualidade pode ser analisada por uma matriz de erros, a qual apresenta na diagonal principal os *pixels* que foram classificados corretamente para cada classe e os elementos fora dela mostram a quantidade de pontos classificados erroneamente. Portanto, quanto menores forem os valores fora da diagonal principal, melhor será o conjunto de amostras.

De forma a analisar as amostras utilizadas no método Maxver, construiu-se a Tabela 3.3 que apresenta a matriz de erros. Esta matriz originada da classificação dos conjuntos de *pixels* das amostras de treinamento, apresenta os tipos de cobertura de solo conhecidos usados para o treinamento (colunas) contra o *pixels* de fato classificados em cada categoria de cobertura de solo (linha), apresentando a distribuição de porcentagens de *pixels* classificados de forma correta ou erroneamente.

Os resultados de classificação não são bons, pois existem áreas de treinamento com variação interna na classe, as classes de treinamento (estrada e edificações) não são espectralmente separáveis e a estratégia estatística de classificação que é empregada apresentará mais erros na classificação. Como observado na Tabela 3.3, alguns alvos ou

objetos na imagem, apesar de serem diferenciados visualmente pela forma ou volume, apresentam *pixels* com valores digitais bastante parecidos (ou até iguais), em função, por exemplo, de fatores como a iluminação do ambiente. Esses alvos podem ser classificados como pertencentes a uma mesma classe temática, independente do método de classificação adotado.


TABELA 3.3 – MATRIZ DE ERRO DA CLASSIFICAÇÃO DO CONJUNTO DE *PIXELS* DE TREINAMENTO

		Exatidão do Usuário (%)	Dados de Referência							Total Linha	
			Floresta	Grama	Água	Estrada	Edificações	Solo Exposto	Não Classificado		
Dados Classificados	Floresta	99.2	119	0	0	0	0	0	0	1	120
	Grama	98.3	0	118	0	0	0	0	0	2	120
	Água	100.0	0	0	120	0	0	0	0	0	120
	Estrada	94.2	0	0	0	113	6	1	0	0	120
	Edificações	90.0	0	0	0	5	108	4	3	0	120
	Solo Exposto	100.0	0	0	0	0	0	120	0	0	120
	Total Coluna		119	118	120	118	114	125	6		720
	Exatidão do Produtor (%)		100.0	100.0	100.0	95.8	94.7	96.0			

Para verificar a classificação pelo método tradicional, executou-se a classificação pelo MaxVer no MultiSpec. Conforme Figura 3.7, as classes geradas são apresentadas com as seguintes cores: azul (água), vermelho (edificações), marrom (solo exposto), verde escuro (vegetação arbórea), verde claro (vegetação rasteira), preto (estrada), branco (*pixels* não classificados). Os *pixels* não classificados referem-se ao percentual de probabilidade de pertencer a classe ser muito baixo, neste caso como parâmetro utilizou-se 2%.

Os resultados apresentados na Figura 3.7 comprovam a dificuldade na distinção de coberturas terrestres como edificações e estrada, pois grande parte da edificações acabou não sendo classificada devido a sua probabilidade ser muito baixa.

FIGURA 3.7 –MAPA TEMÁTICO OBTIDO DA APLICAÇÃO DO MÉTODO MAXVER



3.2. DESENVOLVIMENTO DO MÉTODO PROPOSTO

Com este trabalho deseja-se obter informações de distintos tipos de cobertura de solo, através do desenvolvimento de uma técnica de classificação supervisionada que abrange regras nebulosas integradas às características espectrais pela utilização de imagens de referência. Estas imagens de referência (ou índices) que destacam certas feições foram obtidas através de operações aritméticas entre bandas, sendo combinadas através das regras, de forma a detectar um determinado tipo de cobertura de solo.

Este método foi implementado no *software* MATLAB, utilizando as funções existentes na *toolbox* de Processamento de Imagens e de *Fuzzy*. O sistema foi desenvolvido através de comandos em um script (extensão *.m), devido aos conjuntos nebulosos das variáveis de entrada serem gerados de forma dinâmica abrangendo diferentes características.

Com a aplicação desta nova técnica, busca-se detectar as seguintes classes de cobertura de solo: estrada, edificações, vegetação rasteira, vegetação arbórea e água.

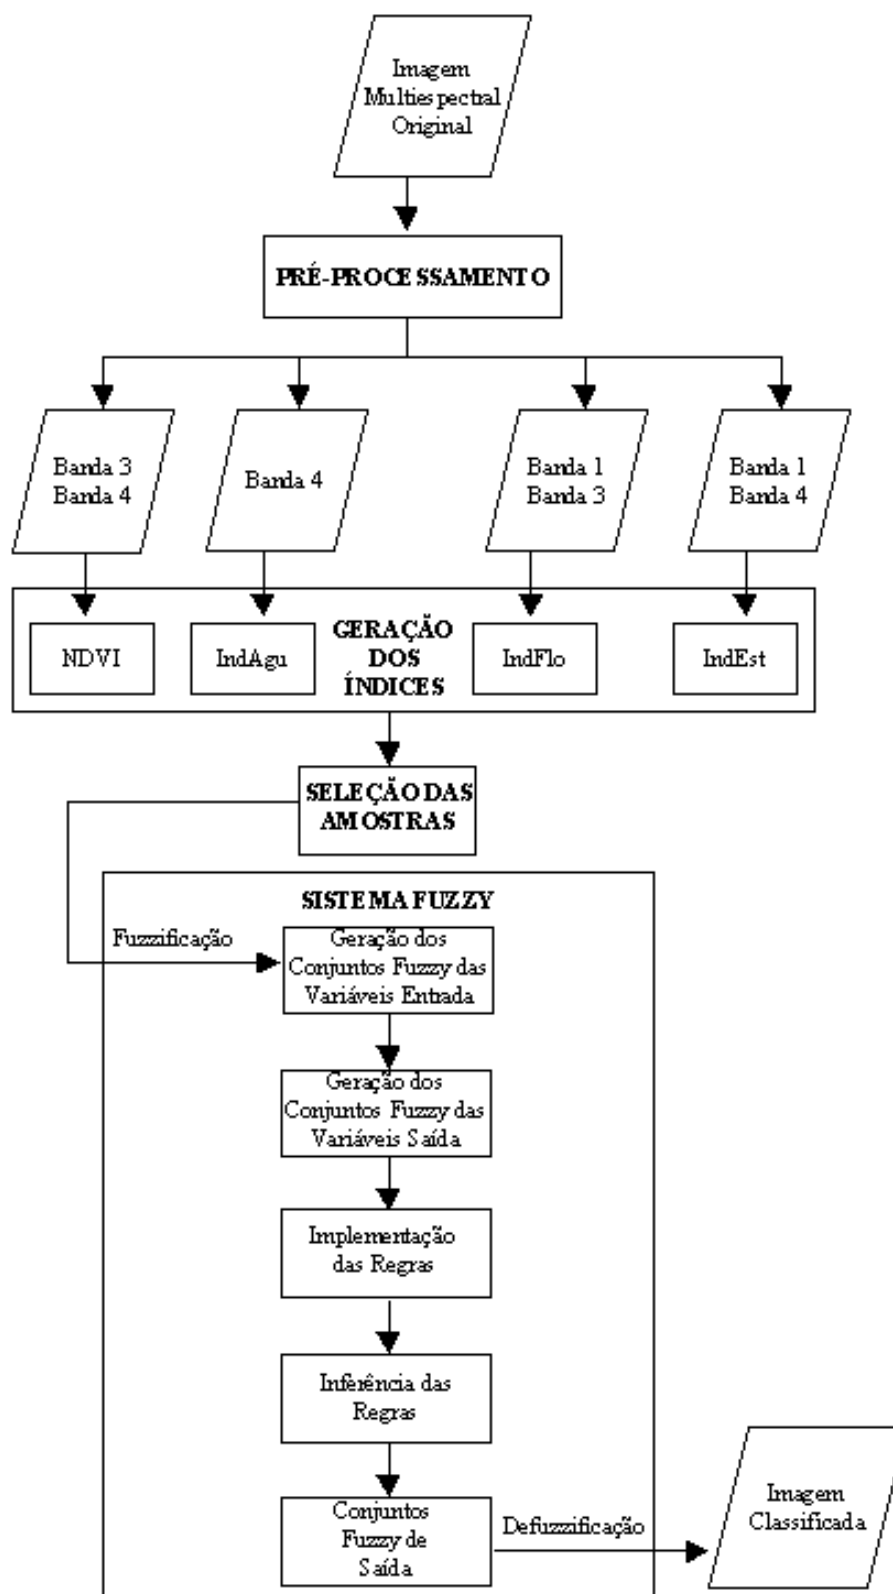
Na Figura 3.8 é apresentado o fluxograma do método proposto, que abrange os seguintes passos:

- Pré-processamento;
- Geração dos índices;
- Seleção das amostras;

Desenvolvimento do sistema nebuloso abrangendo: processo de fuzzificação, onde são gerados os conjuntos nebulosos das variáveis de entrada; geração dos conjuntos nebulosos das variáveis de saída; implementação das regras; inferência das regras; conjuntos fuzzy de saída resultantes e a defuzzificação para obtenção da imagem classificada.

Nos itens seguintes (3.2.1 a 3.2.4) serão explicados de forma detalhada cada etapa do método proposto.

FIGURA 3.8 –FLUXOGRAMA DO MÉTODO PROPOSTO



3.2.1. Pré-Processamento

Na fase de pré-processamento, foi necessário efetuar a correção atmosférica da imagem, de forma a reduzir o efeito da interferência da atmosfera sobre os valores de *pixel* registrados da cena.

Assim, para cada banda foi determinado um valor de *pixel* que representa o efeito de espalhamento, este valor constante foi utilizado na operação de subtração de cada *pixel* da imagem, alterando o valor do mesmo. Os valores constantes utilizados foram: na banda 1, 131; na banda 2, 93; na banda 3, 40 e na banda 4, 4. Na Tabela 3.4 são apresentados os valores originais dos *pixels* e seus valores corrigidos.

TABELA 3.4 – INTERVALO DE VALORES DOS *PIXELS* APÓS A CORREÇÃO ATMOSFÉRICA

BANDAS	VALORES ORIGINAIS	VALORES CORRIGIDOS
Banda 1	131 – 772	0 – 641
Banda 2	93 – 1036	0 – 943
Banda 3	40 – 1349	0 – 1309
Banda 4	4 – 918	0 - 914

3.2.2. Geração dos índices


Neste passo, efetuam-se operações aritméticas entre bandas de forma a gerar índices (imagens de referência) que permitam a discriminação visual dos diversos tipos de cobertura de solo, através de suas propriedades espectrais. A utilização dos índices em substituição as bandas originais deve-se ao fato, dos índices facilitarem a separabilidade das classes. Na Figura 3.9 podem ser observados os histogramas das bandas originais, os quais demonstram-se altamente correlacionados.

As diferentes feições de cobertura terrestre podem ser ressaltadas através de várias operações aritméticas, como é o caso do NDVI (*Normalized Difference Vegetation Index*) (LILLESAND E KIEFER, 1994), que abrange as bandas vermelho e infravermelho de forma a destacar a região de vegetação.

Para facilitar a geração das variáveis nebulosas, os valores de índices obtidos foram padronizados. Por isso, após cada cálculo os valores são distribuídos para o intervalo $[0, 1]$.

Nas Figuras (3.10 a 3.14) podem ser observados os histogramas dos índices gerados, porém, vale ressaltar que para apresentar visualmente estes índices, os mesmos foram reamostrados para abranger todos os níveis de cinza possíveis (0 a 2048) dentro dos limites da imagem.

FIGURA 3.9 – HISTOGRAMA DAS BANDAS ORIGINAIS




3.2.2.1. Índice de vegetação

Os resultados gerados pela aplicação do índice de vegetação NDVI destacam a vegetação existente na cobertura de solo, sendo apresentados no intervalo de valores de -1 a 1. As áreas com vegetação geralmente produzem valores altos de NDVI devido a sua alta reflectância no infravermelho próximo e sua baixa reflectância no vermelho visível. Por outro lado a água, por exemplo, possui mais reflectância no visível do que no infravermelho, portanto, estas classes terão como resultado valores negativos. As áreas de solo exposto resultarão em índices de vegetação próximos de zero. O cálculo é efetuado de acordo com a seguinte fórmula:

$$NDVI = (\text{Infravermelho próximo} - \text{Vermelho}) / (\text{Infravermelho próximo} + \text{Vermelho})$$

A imagem com o índice de vegetação (NDVI) apresentará em níveis de cinza mais claros os locais onde existe vegetação. Como a área de estudo apresenta a superfície coberta por vegetação verde e saudável, a imagem resultante da utilização do índice apresentou a vegetação bastante clara, conforme Figura 3.10.

FIGURA 3.10 –IMAGEM E HISTOGRAMA DO ÍNDICE NDVI



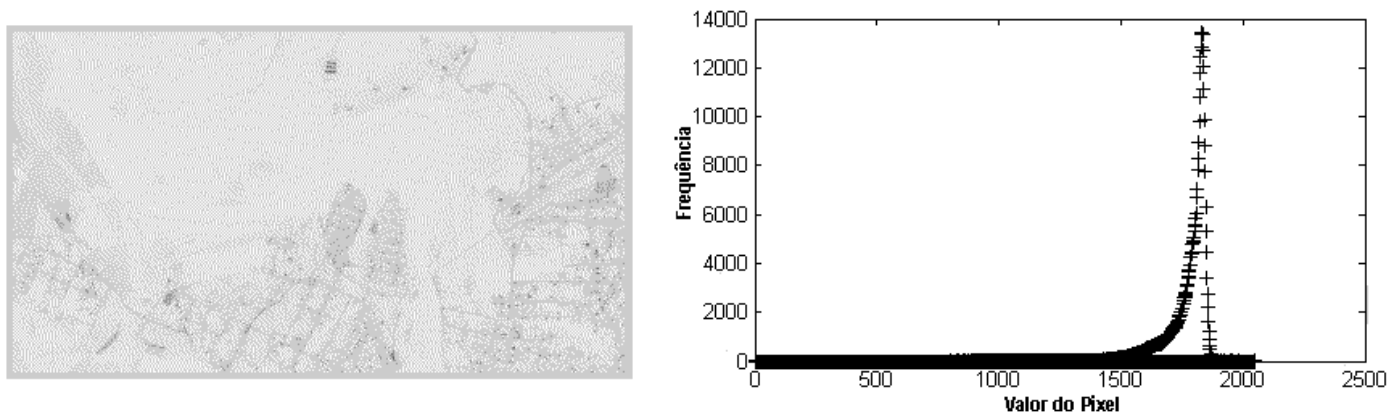
3.2.2.2. Grau de artificialidade

Através do grau de artificialidade obtido do índice Nanda é possível identificar os diversos tipos de artificialidade de feições de cobertura de solo (POLIDÓRIO et al., 2003).

A imagem resultante do grau de artificialidade Nanda (Figura 3.11), apresenta em níveis de cinza mais claras as feições naturais, sendo as feições artificiais mais escuras. Este índice é calculado de acordo com a seguinte fórmula.

$$Nanda = Verde - (Vermelho + Azul)$$


FIGURA 3.11 –IMAGEM E HISTOGRAMA DO ÍNDICE NAND



3.2.2.3. Índice de água

A parte da imagem que se refere a água estava bem destacada por valores de pixels baixos na banda 4 (Infravermelho Próximo), não sendo necessária a geração de um índice (Figura 3.12) que envolvesse mais de uma banda. Apenas para manter o padrão entre os índices, os valores de pixel da respectiva banda foram reamostrados para o intervalo [0, 1].

FIGURA 3.12 –IMAGEM E HISTOGRAMA DO ÍNDICE INDAGU



3.2.2.4. Índice de floresta

Com o objetivo de diferenciar vegetação arbórea de rasteira, inicialmente foram implementados testes utilizando medidas de textura utilizadas nos estudos de SHACKELFORD e DAVIS (2002) e ZHANG (2001). Porém, as imagens resultantes não destacavam as árvores, a ponto de ser possível detectar os limiares necessários para a execução do passo de criação das variáveis de entrada.


Para gerar o índice que destacasse as árvores foram efetuados diversos testes combinando as bandas da imagem. Após análise dos resultados gerados, verificou-se que a razão entre as bandas 1 (Azul) e 3 (Vermelho) destacava de forma satisfatória a cobertura de floresta. Este índice elaborado é chamado de índice de floresta (IndFlo), sendo a seguinte fórmula utilizada para o cálculo do mesmo:

$$\text{IndFlo} = (\text{Vermelho} - \text{Azul}) / (\text{Azul} + \text{Vermelho})$$

A imagem obtida com a aplicação do IndFlo, apresenta em níveis de cinza mais escuros as áreas onde são identificadas as árvores.

Vale ressaltar que a combinação destas bandas nem sempre detectará bem a floresta. A região de estudo contém árvores saudáveis que possuem um tom de verde escuro que ficou ressaltado de forma significativa na Figura 3.13, porém não é em todo tipo de mata que ocorrerão estes resultados. Em um teste efetuado em uma imagem do LandSat o resultado obtido não foi bom.

FIGURA 3.13 –IMAGEM E HISTOGRAMA DO ÍNDICE INDFLO



3.2.2.5. Índice de estrada

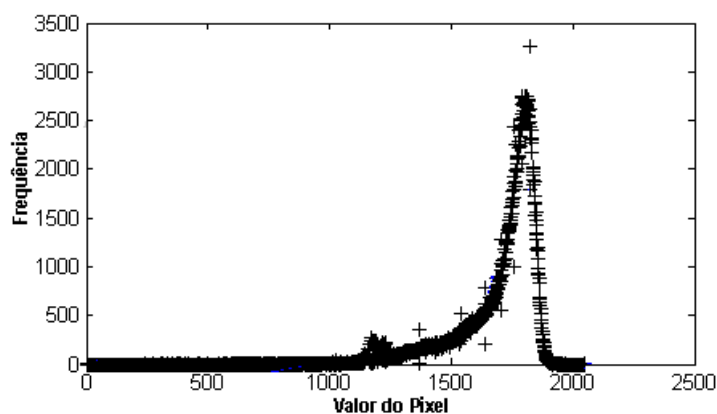

Para destacar as estradas também necessitava-se de uma imagem de referência que pudesse ser utilizada no sistema nebuloso. Para obter um índice para a estrada foram efetuados testes com a banda 1 (Azul), banda 2 (Verde) e a banda 4 (Infravermelho Próximo), sendo utilizadas as seguintes fórmulas:

$$\text{IndEst} = (\text{IV Próximo} - \text{Azul}) / (\text{Azul} + \text{IV Próximo})$$

$$\text{IndEst} = (\text{IV Próximo} - \text{Verde}) / (\text{IV Próximo} + \text{Verde})$$

Ao analisar os resultados gerados, optou-se pela fórmula do item a), que destacou melhor os locais da imagem que se referem a estrada. A imagem com o índice de estrada (IndEst), apresenta em níveis de cinza mais escuros as áreas onde foram identificadas as estradas. Mas, devido a sobreposição espectral existente entre as classes estrada e edificações, este índice não demonstrou resultados totalmente satisfatórios.

FIGURA 3.14 –IMAGEM E HISTOGRAMA DO ÍNDICE INDEST



3.2.3. Seleção das Amostras

O método proposto neste trabalho é supervisionado, pois foram efetuadas as seleções de pequenas amostras de cada tipo de cobertura de solo que pretende-se classificar.

Na imagem a ser classificada foram consideradas como classes: edificações, estrada, vegetação arbórea, vegetação rasteira e água, sendo selecionadas para cada classe 10 amostras contendo 4 *pixels* cada.

3.2.4. Criação do Sistema Nebuloso

3.2.4.1. Fuzzificação

Neste passo, é efetuado o processo de fuzzificação, onde os valores precisos da imagem serão transformados em conjuntos nebulosos que representarão as funções de pertinência das variáveis lingüísticas definidas. A fuzzificação descreve a transição de um sistema *crisp* para um sistema nebuloso, assinalando os valores de pertinência entre 0 e 1 para cada característica que deverá ser representada.

Os índices geram as imagens de referência que definem as variáveis de entrada. Assim, o NDVI, NandA, IndAgu, IndFlo e IndEst geram respectivamente as seguintes variáveis de entrada nebulosa: vegetação, artificial, água, floresta e estrada.

A cada variável nebulosa, são atribuídos dois conjuntos nebulosos que correspondem as funções de pertinência: “bom” e “ruim” (Figura 3.15). Essas funções de pertinência foram definidas na forma trapezoidal. Este formato foi escolhido pois permite que vários valores possam ser identificados como pertinência total (grau de pertinência 1). Na forma triangular a transição seria menos gradual, visto que apenas um valor possui pertinência total.

A função de pertinência “bom” de cada variável de entrada sempre retrata a mesma idéia, por exemplo, no caso da variável Vegetação, indica que há um intervalo de valores que com certeza é vegetação e outro intervalo com valores acima ou abaixo de um determinado

limiar que representam a pertinência parcial neste conjunto de vegetação.

A função de pertinência “ruim” de cada variável de entrada sempre retrata a mesma idéia, por exemplo, no caso da variável Vegetação, indica que há um intervalo de valores que com certeza não é vegetação e outro intervalo com valores acima ou abaixo de um determinado limiar que representam a pertinência parcial neste conjunto de não vegetação.

As funções de pertinência na forma trapezoidal são definidas através de quatro parâmetros. Estes parâmetros foram gerados a partir das amostras das imagens resultantes da aplicação dos índices, conforme descrito a seguir.

Na Tabela 3.5 está descrito o valor do 1º limiar (*crisp*), isto é, os valores que foram determinados inicialmente através das amostras do índice gerado. Para determinar os limiares, efetuaram-se testes com:

- a) valor mínimo das amostras para índice com classe destacada por valor claro;
- b) valor máximo da amostra para índice com classe destacada por valor escuro.

Nos índices IndFlo e IndEst utilizados respectivamente na geração das variáveis de entrada Floresta e Estrada foi mais difícil definir o valor de limiar, pois não foi possível obter um bom resultado com o valor mínimo ou máximo das amostras. Neste caso, utilizou-se a média das amostras como limiar.

Nas Tabela 3.6 e 3.7 são apresentadas as fórmulas utilizadas para gerar os parâmetros 1 e 2 que foram utilizados no processo de fuzzificação, ou seja, os valores que definem os parâmetros dos conjuntos “bom” (conjuntos que determinam vegetação, água, floresta, estrada e artificial) e “ruim” (conjuntos que determinam não-vegetação, não-água, não-floresta, não-estrada e não-artificial).

Neste caso, aplicou-se ao valor do limiar *crisp* obtido uma margem de incerteza. Para definir esta margem de incerteza efetuaram-se diversos testes de execução de regras, avaliando quais os parâmetros ideais para serem utilizados nas funções de pertinência: “bom” e “ruim”. Ao final definiu-se que para o conjunto “bom” a melhor margem de incerteza foi 0.05 e para o conjunto “ruim” foi 0.10.

FIGURA 3.15 – VARIÁVEIS DE ENTRADA E SAÍDA NEBULOSAS

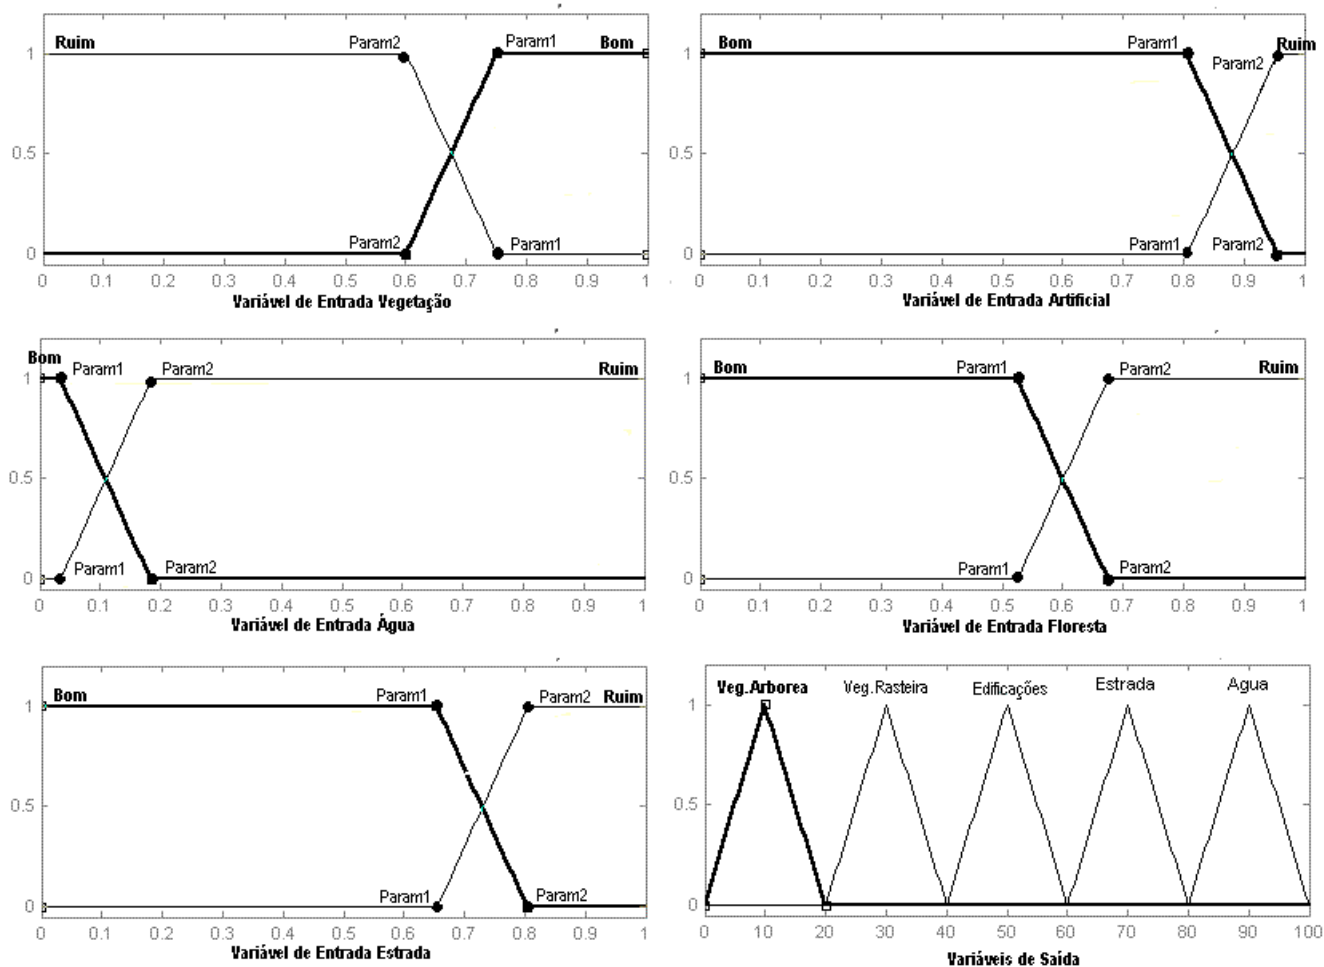


TABELA 3.5 – RESUMO DOS VALORES DE LIMIAR

Variável	Cálculo	Valor
Vegetação	Valor mínimo das amostras	0.7008
Artificial	Valor máximo das amostras	0.8559
Água	Valor máximo das amostras	0.0842
Floresta	Valor médio das amostras	0.5756
Estrada	Valor médio das amostras	0.7045

TABELA 3.6 – RESUMO DOS VALORES DO PARÂMETRO 1

Variável	Cálculo do Parâmetro1	Parâmetro1
Vegetação	Valor de limiar + 0.05	0.7508
Artificial	Valor de limiar - 0.05	0.8059
Água	Valor de limiar - 0.05	0.0342
Floresta	Valor de limiar - 0.05	0.5256
Estrada	Valor de limiar - 0.05	0.6546

TABELA 3.7 – RESUMO DOS VALORES DO PARÂMETRO 2

Variável	Cálculo do Parâmetro2	Parâmetro2
Vegetação	Valor de limiar - 0.10	0.6008
Artificial	Valor de limiar + 0.10	0.9559
Água	Valor de limiar + 0.10	0.1842
Floresta	Valor de limiar + 0.10	0.6756
Estrada	Valor de limiar + 0.10	0.8046

3.2.4.2. Geração das variáveis de saída

O importante nos conjuntos nebulosos de funções de pertinência das variáveis de saída é que os mesmos possuam todos os graus de pertinência possíveis, por isso, selecionou-se a forma triangular e mesmo tamanho para cada saída.

Os intervalos definidos para início e fim do conjunto são importantes no momento da execução das regras, pois no MATLAB retorna-se o valor gerado, mas necessariamente no caso da classificação de imagens precisa-se da classe correspondente ao valor. Então, definiu-se a variável de saída chamada Classe (Figura 3.15) que possui as seguintes funções de pertinência: vegetação arbórea, vegetação rasteira, edificações, estrada e água.

3.2.4.3. Implementação das regras

As regras nebulosas foram geradas de forma a relacionar os diversos resultados obtidos com as combinações de bandas, sendo definidas da seguinte forma:

Com a utilização do índice de artificialidade NandA (Figura 3.16):

Regra 1: Se Vegetacao = Bom e Floresta = Bom Entao Classe = Vegetação Arbórea

Regra 2: Se Vegetacao = Bom e Floresta = Ruim Entao Classe = Vegetação Rasteira

Regra 3: Se Vegetacao = Ruim e Agua = Ruim e Artificial = Bom e Estrada = Ruim Entao Classe = Edificações

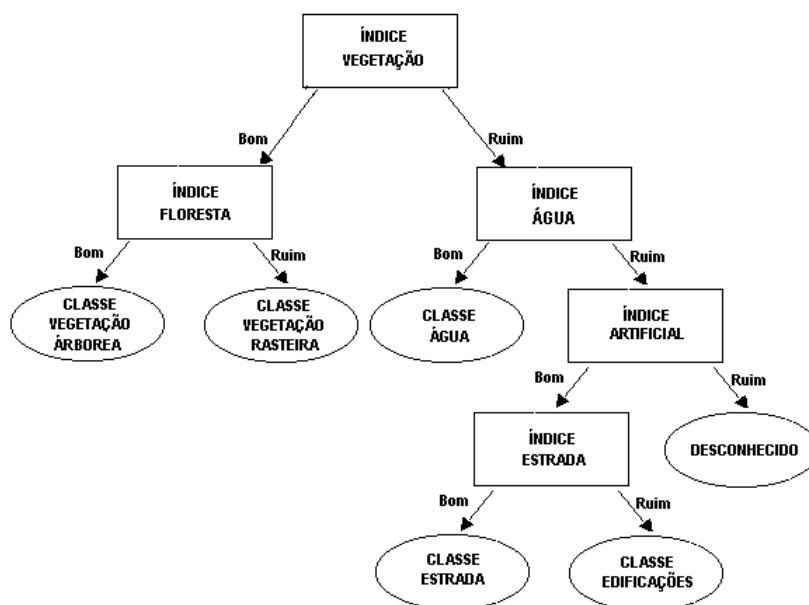
Regra 4: Se Vegetacao = Ruim e Agua = Ruim e Artificial = Bom e Estrada = Bom e Entao Classe = Estrada

Regra 5: Se Vegetacao = Ruim e Agua = Bom Entao Classe = Agua

Regra 6: Se Vegetacao = Ruim e Agua = Ruim e Artificial = Ruim Entao Classe =

Desconhecido

FIGURA 3.16 – REPRESENTAÇÃO DAS REGRAS (COM NANDA) EM ÁRVORE DE DECISÃO



Sem a utilização do índice de artificialidade NandA (Figura 3.17):

Regra 1: Se Vegetacao = Bom e Floresta = Bom Entao Classe = Vegetação Arbórea

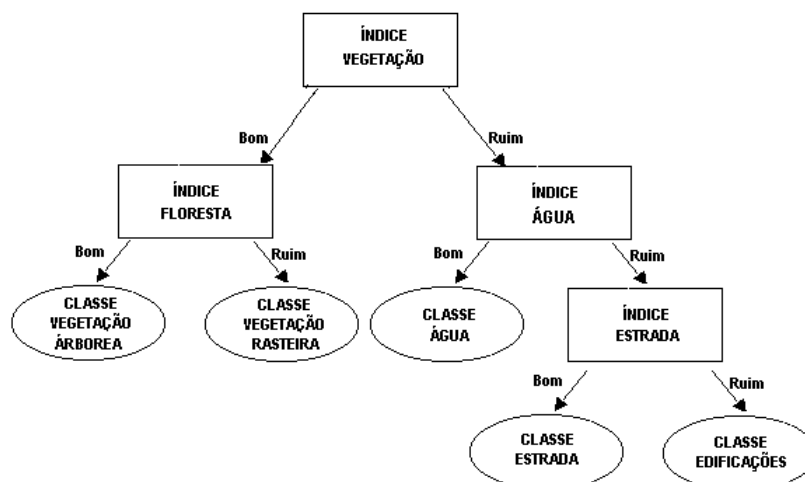
Regra 2: Se Vegetacao = Bom e Floresta = Ruim Entao Classe = Vegetação Rasteira

Regra 3: Se Vegetacao = Ruim e Agua = Ruim e Estrada = Ruim Entao Classe = Edificações

Regra 4: Se Vegetacao = Ruim e Agua = Ruim e Estrada = Bom Entao Classe = Estrada

Regra 5: Se Vegetacao = Ruim e Agua = Bom Entao Classe = Agua

FIGURA 3.17 – REPRESENTAÇÃO DAS REGRAS (SEM NANDA) EM ÁRVORE DE DECISÃO



3.2.4.4. Inferência das regras

O sistema nebuloso foi gerado utilizando o método de inferência de Mandani. A operação utilizada no método And foi min e no Or foi max. Na implicação utilizou-se min e na agregação max.

Na execução das regras o valor de entrada de cada variável foi: NDVI para variável vegetação, Nanda para variável Artificial, IndAgu para a variável água, IndFlo para a variável vegetação rasteira e IndEst para a variável estrada.

3.2.4.5. Defuzzificação


O resultado da classificação do sistema nebuloso gerado é obtido ao efetuar um loop em todos os *pixels* das imagens dos índices NDVI, Nanda, IndAg, IndFlo e IndEst.

Os conjuntos fuzzy de saída resultantes são defuzzificados pelo método MoM (média dos máximos). O MATLAB então retorna o valor defuzzificado e através do mesmo é efetuada uma verificação de que variável de saída pertence, de forma a identificar o nome da classe para que seja gerado o mapa temático da imagem.

3.2.5. Verdade de Terreno

Para analisar os resultados gerados na classificação do método proposto, foi efetuada a verificação em campo, coletando-se amostras de verdade de terreno. Devido a defasagem temporal de 3 anos entre a tomada das imagens e o levantamento, tomaram-se alguns cuidados, como por exemplo, considerar somente edificações que tivessem sido construídas a mais de 3 anos. Foram efetuados 141 registros contendo mais de uma amostra de determinada cobertura terrestre, sendo descritos na relação apresentada no Apêndice. Esta relação foi necessária para que pudessem ser geradas as tabelas de erros do método proposto e da máxima verossimilhança. Os registros efetuados estão enumerados na cor vermelha na Figura 3.18. Algumas áreas de verificação podem ser observadas nas três pequenas figuras, sendo sua localização indicada na imagem. Estas três pequenas imagens correspondem respectivamente aos registros 92, 88 e 69 que são descritos detalhadamente no Apêndice.

FIGURA 3.18 – LOCALIZAÇÃO DAS AMOSTRAS DE VERDADE DE TERRENO



4. RESULTADOS

As imagens classificadas através da execução das regras (a) e (b) descritas no item 3.2.4.3 são apresentadas nas Figuras 4.1 e 4.2, onde as classes são apresentadas com as seguintes cores: azul (água), vermelho (edificações), verde escuro (vegetação arbórea), verde claro (vegetação rasteira), preto (estrada) e desconhecido (branco).

Analisando-se visualmente as imagens classificadas (Figura 4.1 e 4.2), verifica-se que o resultado obtido com a utilização do índice NandA (Figura 4.1) foi muito semelhante ao obtido quando não utilizado o índice (Figura 4.2). Esta semelhança nos resultados ocorreu porque o índice NDVI efetua inicialmente uma separação na imagem, gerando a parte que é identificada como vegetação e o que é “não-vegetação”. A porção de “não-vegetação” corresponde a todas as classes diferentes de vegetação arbórea e rasteira. Porém, ao utilizar o índice NandA também são destacadas como artificial as mesmas classes que em “não-vegetação” (estrada, edificações e solo exposto), com exceção da classe água.

Assim, devido à pouca informação que acrescenta no processo, a utilização do índice NandA não foi necessária, pois apenas com a utilização do índice NDVI nas regras já é possível separar elementos artificiais e naturais, excetuando-se solo exposto, o qual também não é identificado como natural pelo índice NandA. Face a isto, na análise dos resultados foram utilizadas as regras do item (b), ou seja, a imagem resultante das regras sem a utilização do índice NandA (Figura 4.2).

FIGURA 4.1 – IMAGEM CLASSIFICADA PELO MÉTODO PROPOSTO UTILIZANDO O ÍNDICE NANDA




FIGURA 4.2 –IMAGEM CLASSIFICADA PELO MÉTODO PROPOSTO SEM A UTILIZAÇÃO DO ÍNDICE NANDA



4.1. ANÁLISE DOS RESULTADOS

Ao classificar a imagem há vários fatores que influenciam no resultado. Inicialmente, deve-se destacar que o método implementado não possui uma regra específica para detectar solo exposto e, portanto as áreas da imagem que possuem este tipo de cobertura foram classificadas como edificações.

A imagem classificada retrata certa confusão entre a classe estrada e edificações, isto se deve ao fato da mesma possuir uma variação muito grande de materiais utilizados em estradas e telhados de edificações. Conforme apresentado na Figura 3.18, as estradas podem ser: de terra, de asfalto, de asfalto contendo porções cobertas por terra, ruas que apresentam sombras de árvores em determinado percurso, ruas de pedra, ruas de areia, paralelepípedo e a linha férrea. E, na Figura 3.18, também podem ser observados os diversos tipos de materiais utilizados nos telhados das edificações como: cerâmica, barro, eternit.

As ruas de asfalto são espectralmente semelhantes às construções que possuem telhas na cor cinza e, a terra em estradas pode ser confundida com construções que possuem telhas de barro ou cerâmica. Além destas semelhanças espectrais, o índice utilizado para detectar a estrada não teve resultado satisfatório. Porém, se considerar na imagem estrada e edificações como uma classe única chamada de "não permeável" seria possível verificar que o método detectou de forma satisfatória.

Se a área de classificação estivesse coberta somente por um tipo de vegetação então a classificação seria uma tarefa simples. Obviamente este não é o caso, mas o índice utilizado para detecção de floresta, embora não possa ser aplicado para qualquer tipo de mata, nesta imagem apresentou ótimos resultados, separando muito bem vegetação arbórea de vegetação rasteira.

4.1.1. Análise Visual

As Figuras 4.3 e 4.4 apresentam pequenas áreas da imagem comparando a cena original com os resultados obtidos pela classificação com Isodata (5 *clusters*), MaxVer e pelo

método proposto. Pode-se observar pelas figuras que:

a) No método Isodata:

- Na Figura 4.3 nota-se que grande parte da vegetação arborea e da estrada de ferro foi agrupada juntamente com a água. As estradas de asfalto apresentaram-se bem delineadas, porém neste agrupamento foram inseridas algumas edificações.

- Na Figura 4.4 verifica-se o mesmo problema na detecção das feições de água, vegetação arborea e estrada de ferro. As estradas não foram bem detectadas, pois nesta figura as mesmas são de terra e cascalho, tendo semelhança espectral com os telhados de eternit. Neste caso, observa-se que não foi possível separar as informações de edificações e estradas corretamente.

b) No método MaxVer:

- Na Figura 4.3 nota-se que muitos *pixels* não foram classificados, principalmente os que se referem a classe de vegetação rasteira e edificações. Parte das estradas foi classificada como edificações.

- Na Figura 4.4, o Rio Negro não foi bem delineado, apresentando também *pixels* não classificados, devido as áreas de sombra próximas da água.

c) No método proposto:

- Na Figura 4.3 observa-se que a vegetação arborea e rasteira foi bem detectada. A estrada de ferro está bem delineada, porém alguns *pixels* deste tipo de cobertura foram incorretamente classificados como água. As estradas de asfalto foram identificadas, com algumas edificações agrupadas incorretamente nesta mesma classe.

- Na Figura 4.4, o Rio Negro foi bem delineado. As estradas não foram bem detectadas, pois nesta figura as mesmas são de terra e cascalho, tendo semelhança espectral com os telhados de eternit. Neste caso, observa-se que não foi possível separar as informações de edificações e estradas corretamente

FIGURA 4.3 – COMPARAÇÃO DO RESULTADO DA CLASSIFICAÇÃO – ÁREA 1 (ISODATA COM 05 CLUSTERS, MAXVER E MÉTODO PROPOSTO)

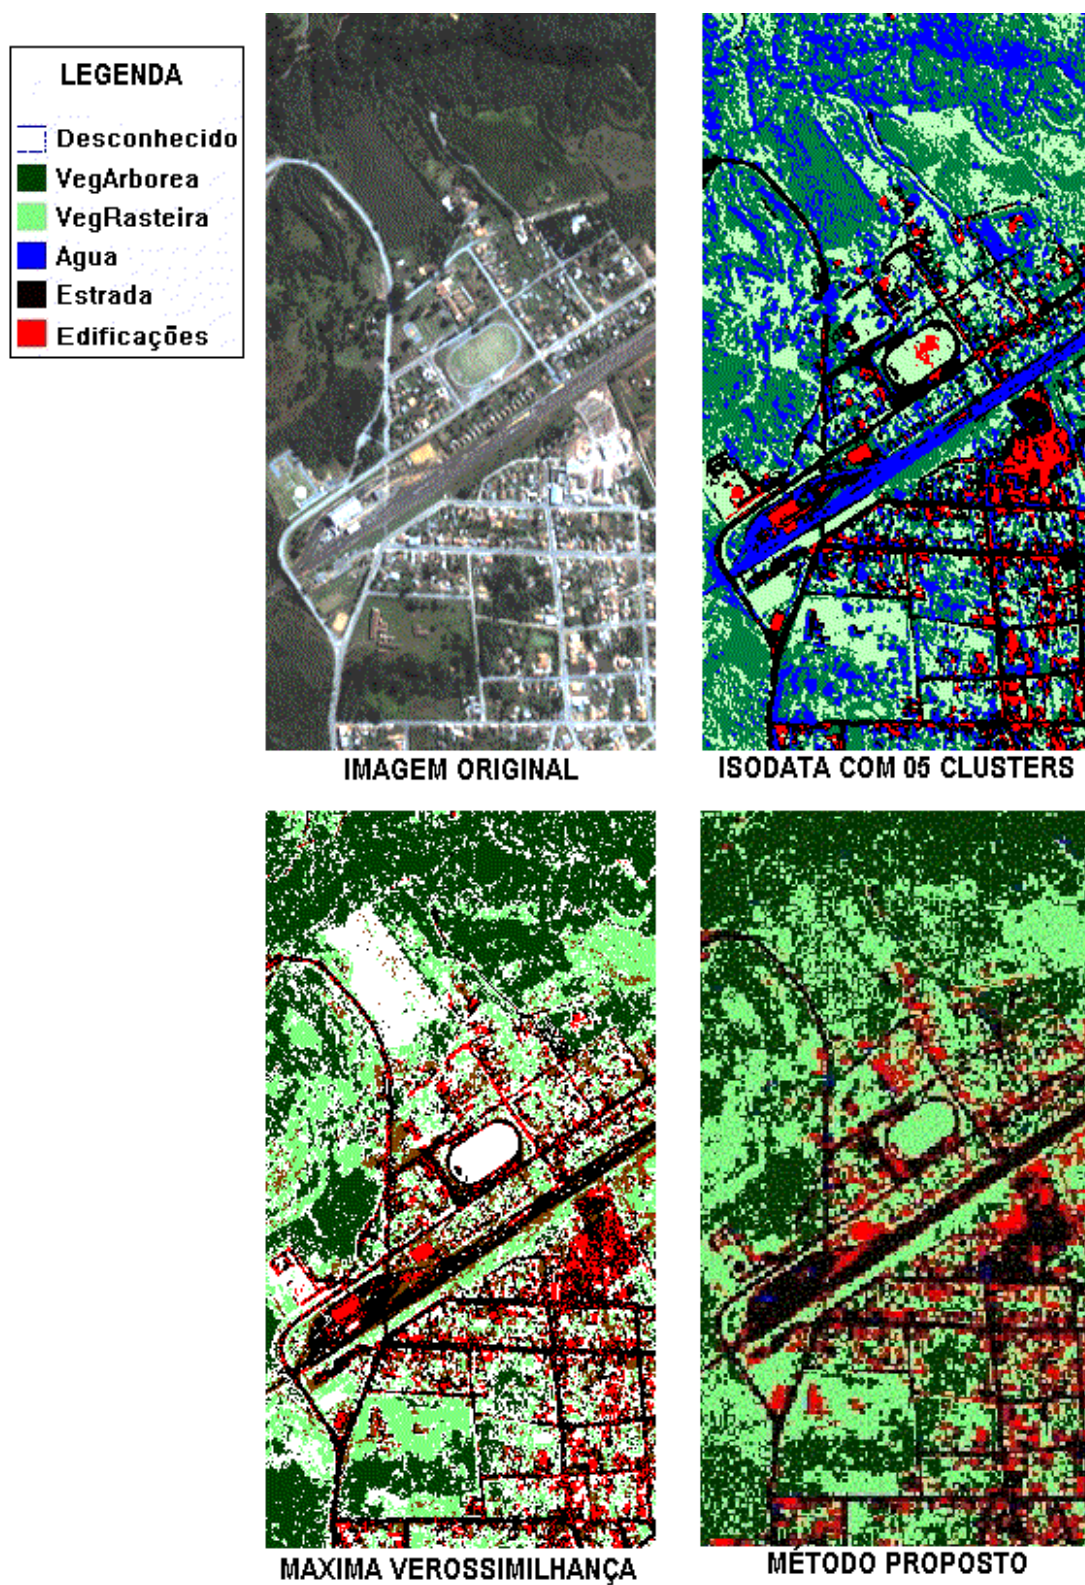
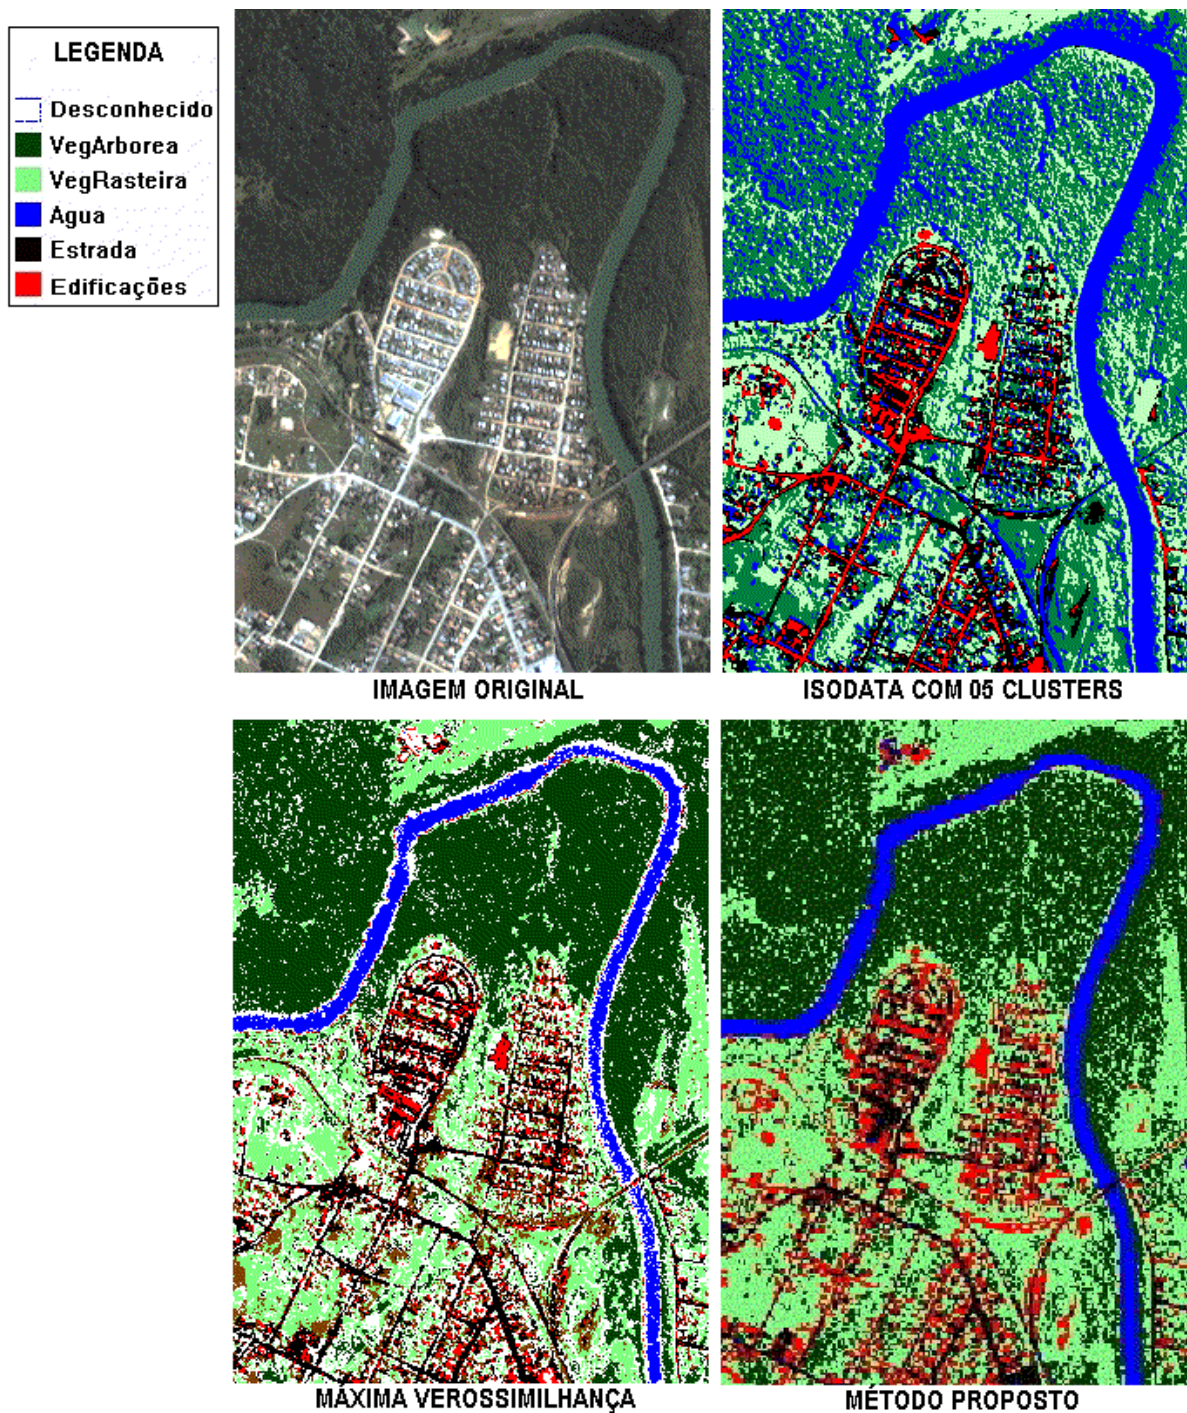


FIGURA 4.4 – COMPARAÇÃO DO RESULTADO DA CLASSIFICAÇÃO – ÁREA 2 (ISODATA COM 05 CLUSTERS, MAXVER E MÉTODO PROPOSTO)



4.1.2. Análise Estatística

Para efetuar a análise estatística foi utilizada a matriz de erro que compara os dados de referência que representam a "verdade terrestre" com os dados resultantes de uma classificação. As Tabelas 4.1, 4.3 e 4.5 apresentam as matrizes de erros, listando os tipos de cobertura conhecidos (colunas) contra o *pixels* de fato classificados em cada classe de cobertura de solo (linha). E nas Tabelas 4.2, 4.4 e 4.6 são apresentadas a exatidão: global, do usuário e do produtor de cada matriz de erro.

As Tabelas 4.1 e 4.3 apresentam as matrizes de erros geradas com o método MaxVer, com e sem a utilização da classe solo exposto. A Tabela 4.5 apresenta a matriz de erro do método proposto. Ao comparar as tabelas (4.1 e 4.3) das matrizes de erro, nota-se que a exatidão global do método proposto é de 85.2%, sendo aproximadamente 35% superior ao resultado obtido pelo método MaxVer.

Com relação a exatidão do usuário, as classes de vegetação arbórea, vegetação rasteira e edificações tiveram respectivamente um aumento de 30%, 46% e 36% em relação ao resultado obtido pela classificação da máxima verossimilhança, tendo apenas a classe estrada um decremento de 8% na exatidão do usuário, devido as classes estrada e edificações possuírem semelhança espectral. Porém, se considerada a exatidão média para estrada e construção, tem-se 76,45% para o método proposto contra 69.15% do maxver e para vegetação arbórea e rasteira, a exatidão média do método proposto é de 98.55% contra 71.75% do maxver.

TABELA 4.1 – MATRIZ DE ERRO DA CLASSIFICAÇÃO DAS AMOSTRAS DE VERDADE DE TERRENO NO MAXVER COM SOLO EXPOSTO

		Dados de Referência							
		Vegetação Arbórea	Vegetação Rasteira	Água	Estrada	Edificações	Solo Exposto	Não Classificado	Total Linha
Dados	Veget. Arbórea	48	0	0	0	0	3	11	62
	Veget. Rasteira	0	47	0	0	0	3	21	71
Classificados	Água	0	0	2	0	0	0	2	4
	Estrada	0	1	0	75	5	2	10	93
	Edificações	0	0	0	6	45	18	44	113
	Solo Exposto	0	0	0	0	3	5	2	10
	Total Coluna	48	48	2	81	53	31	90	353

TABELA 4.2 – EXATIDÃO GLOBAL, DO PRODUTOR E USUÁRIO (TABELA 4.1)

Classes	Exatidão do Produtor	Exatidão do Usuário
Veget. Arbórea	100	77.4
Veget. Rasteira	97.9	66.1
Água	100	50.0
Estrada	92.5	80.6
Edificações	84.9	39.8
Solo Exposto	16.0	50.0
Exatidão Global		62.8

TABELA 4.3 – MATRIZ DE ERRO DA CLASSIFICAÇÃO DAS AMOSTRAS DE VERDADE DE TERRENO NO MAXVER SEM SOLO EXPOSTO

		Dados de Referência						
		Vegetação Arbórea	Vegetação Rasteira	Água	Estrada	Edificações	Não Classificado	Total Linha
Dados	Veget. Arbórea	48	0	0	0	3	11	62
	Veget. Rasteira	0	47	0	0	3	21	71
Classificados	Água	0	0	2	0	0	2	4
	Estrada	0	1	0	75	7	10	93
	Edificações	0	0	0	6	71	46	123
Total Coluna		48	48	2	81	84	90	353

TABELA 4.4 – EXATIDÃO GLOBAL, DO PRODUTOR E USUÁRIO (TABELA 4.3)

Classes	Exatidão do Produtor	Exatidão do Usuário
Veget. Arbórea	100	77.4
Veget. Rasteira	97.9	66.1
Água	100	50.0
Estrada	92.5	80.6
Edificações	84.5	57.7
Exatidão Global		62.8

A matriz de confusão permite o cálculo de vários índices de precisão. O mais conhecido e indicado para classificações temáticas por representar toda a matriz confusão é o coeficiente Kappa (k). Este índice considera todos os elementos da matriz de confusão, ao invés de somente utilizar os elementos da diagonal, como ocorre com a maioria dos índices. A seguir é apresentado o cálculo de Kappa para a matriz de erro apresentada na Tabela 4.2.

$$\sum_{i=1}^r x_{ii} = 48 + 47 + 2 + 75 + 71 = 243$$

$$\sum_{i=1}^r (x_{i+} \cdot x_{+i}) = (62 * 48) + (71 * 48) + (4 * 2) + (93 * 81) + (123 * 84) = 24.257$$

$$k = \frac{353(243) - 24257}{(353)^2 - 24257} = 0.61$$

TABELA 4.5 – MATRIZ DE ERRO DA CLASSIFICAÇÃO DAS AMOSTRAS DE VERDADE DE TERRENO NO MÉTODO PROPOSTO

		Dados de Referência						Total Linha
		Vegetação Arbórea	Vegetação Rasteira	Agua	Estrada	Edificações	Não Classificado	
Dados	Veget. Arbórea	62	0	0	0	0	0	62
	Veget. Rasteira	0	69	0	0	1	1	71
Classificados	Agua	0	0	4	0	0	0	4
	Estrada	0	0	1	69	21	2	93
	Edificações	0	0	0	20	97	6	123
Total Coluna		62	69	5	89	119	9	353

TABELA 4.6 – EXATIDÃO GLOBAL, DO PRODUTOR E USUÁRIO (TABELA 4.5)

Classes	Exatidão do Produtor	Exatidão do Usuário
Veget. Arbórea	100	100.0
Veget. Rasteira	100	97.1
Agua	0.80	100.0
Estrada	77.5	74.1
Edificações	81.5	78.8
Exatidão Global		85.2

A seguir é apresentado o cálculo de Kappa para a matriz de erro apresentada na Tabela 4.5.

$$\sum_{i=1}^r x_{ii} = 62 + 69 + 4 + 69 + 97 = 301$$

$$\sum_{i=1}^r (x_{i+} \cdot x_{+i}) = (62 * 62) + (71 * 69) + (4 * 5) + (93 * 89) + (123 * 119) = 31677$$

$$k = \frac{353(301) - 31677}{(353)^2 - 31677} = 0.80$$

Os valores Kappa (0.61 ou 0.80) obtido pelas Tabelas 4.3 e 4.5 indicam que a classificação efetuada é 61% ou 80% melhor que a esperada ao acaso, isto é, de forma arbitrária. O valor k gerado pelo método proposto é aproximadamente 31% superior ao valor gerado para maxver, considerando que valores próximos a 1 indicam pleno acordo entre a realidade e o resultado da classificação, enquanto que um valor próximo a 0 sugere que o resultado é puramente gerado ao acaso.

5. DISCUSSÃO E CONCLUSÕES

5.1. CONCLUSÕES

O presente estudo discorreu sobre as etapas para a criação de um sistema baseado em regras nebulosas para a classificação de imagens multiespectrais com resolução espacial de 4 metros obtidas pelo IKONOS. O classificador foi desenvolvido utilizando-se o *software* MATLAB 6.0, tendo como objetivo detectar as seguintes coberturas de solo: vegetação arbórea, vegetação rasteira, água, edificações e estrada.

As regras nebulosas foram construídas a partir da combinação de diversas bandas espectrais chamadas de índices, de forma a ressaltar diversas feições de cobertura de solo, proporcionando maior distinção das feições terrestres com relação aos métodos que utilizam apenas a informação de uma banda individualmente. As imagens de referência que ressaltam determinadas feições foram combinadas, gerando a classificação.

Através de visitas a campo, foram coletadas informações de verdade de terreno, de forma a comparar o método proposto com o MaxVer. Na aplicação do método Isodata verificou-se semelhanças espectrais, pois alguns *pixels* das árvores foram confundidos com a água e, grande parte das estradas misturaram-se às informações de edificações. No método

MaxVer muitos *pixels* não foram classificados, principalmente os que se referem à classe de vegetação rasteira e edificações.

A exatidão global do método proposto é aproximadamente 35% superior ao resultado obtido pelo método MaxVer, sendo que devido à grande semelhança espectral entre estrada e edificações, a classe estrada teve um decréscimo de 8% na exatidão do usuário, porém as demais classes como vegetação arbórea, vegetação rasteira e edificações tiveram respectivamente um aumento de 30%, 46% e 36% em relação ao resultado obtido pela classificação da máxima verossimilhança.

O tempo de execução deste sistema nebuloso é superior a um método *crisp*, como por exemplo, o método da máxima verossimilhança, assim o aperfeiçoamento dos resultados poderia depender de regras ainda mais específicas, que talvez implicassem em consequente aumento do custo computacional, porém sendo compensado pela melhoria na classificação resultante.

Além de gerar bons resultados, este tipo de método apresenta vantagens, como a flexibilidade, pois no caso de anomalias nos resultados interpretados pelas regras é possível efetuar correções nas mesmas, buscando um resultado melhor. A inserção de novas regras ao sistema também é simplificada, permitindo uma substancial modularidade no sistema, ou seja, uma mesma sequência de operações pode, com nenhum ou pequenos ajustes de parâmetros, ser utilizada sobre outra imagem proporcionando o mesmo efeito.

Em um sistema nebuloso não há a necessidade de se assumir nenhuma distribuição específica de classes de cobertura, como no caso do método da máxima verossimilhança, onde consideram-se as classes de cobertura como sendo normalmente distribuídas. Além disso, as regras de lógica nebulosa garantem a transparência das regras de decisão, permitindo a combinação de diversas características, conforme demonstrado no experimento.

A heterogeneidade de características apresentadas na região da imagem, garantiu uma melhor avaliação dos resultados da classificação, demonstrando que o classificador implementado gerou resultados satisfatórios superiores ao método da máxima verossimilhança, embora novos estudos mais aprofundados sejam necessários para uma

melhor detecção das classes de estrada e edificações.

5.2. TRABALHOS FUTUROS

Para trabalhos futuros pode-se efetuar o refinamento do método proposto através das seguintes sugestões. Inicialmente podem ser realizados novos experimentos com outras imagens de alta resolução, reavaliando o método proposto e aprimorando-o.

Uma melhoria que pode ser efetuada é a inclusão de novas regras que utilizem a resolução espacial da imagem pancromática ou a imagem resultante da fusão da imagem pancromática com a multiespectral. Neste caso, utilizando-se destas imagens híbridas pode-se também efetuar testes com outras medidas de textura ao invés da combinação de bandas para a detecção de vegetação arborea.

Devido a detecção de estradas não ter sido satisfatória ao utilizar-se o índice IndEst, pode-se pesquisar e implementar outras técnicas para a definição do índice ou de uma imagem de referência que permita detectar melhor as estradas. Além disto, podem-se comparar os resultados obtidos com outros métodos de classificação atualmente implementados em aplicativos como o ENVI.

REFERÊNCIAS BIBLIOGRÁFICAS

- AMINI, J.; LUCAS, C.; SARADJIAN, M. R.; AZIZI, A.; SADEGHIAN, S. *Fuzzy Logic System For Road Identification Using IKONOS Images*. **Photogrammetric Record**, v. 17(99), p. 493-503, 2002
- BÁRDOSSY, A.; SAMANIEGO, L. *Fuzzy Rule-Based Classification of Remotely Sensed Imagery*. **IEEE Transactions on Geoscience and Remote Sensing**, v. 40, n. 2, p. 362-374, fev. 2002.
- BEZDEK, J. C.; PAL, S. K. **Fuzzy Models for Pattern Recognition**, 1 ed. Piscataway: IEEE Press, 1992.
- BEZDEK, J. C. A Review of Probabilistic, *Fuzzy*, and Neural Models for Pattern Recognition. In: CHEN, C.H. **Fuzzy Logic and Neural Network Handbook**, Estados Unidos: McGraw-Hill, 1996, p. 2.1-2.33.
- BIEHL, L.; LANDGREBE, D. MultiSpec-a tool for multispectral-hyperspectral image data analysis. **Computers & Geosciences**, v. 28, n. 10, p. 1153-1159, 2002.
- CHENG, H. D.; JIANG, X. H.; SUN, Y.; WANG, J. Color Image Segmentation: Advances and Prospects. **Pattern Recognition**, v. 34, p. 2259-2281, 2001.
- CHUVIECO, E. **Fundamentos de Teledetección Espacial**. Madrid: Ediciones Rialp S.A., 1990.
- CITYBRAZIL. Disponível em: <<http://www.citybrazil.com.br>> Acesso em 27/08/2003
- CURRAN, P.J. **Principles of Remote Sensing**. 2.ed. New York: Longman Scientific & Technical, 1992.
- CRÓSTA, A.P. **Processamento Digital de Imagens de Sensoriamento Remoto**. Campinas: Instituto de Geociências/UNICAMP, 1992.
- FACON, J. Operadores Morfológicos em Níveis de Cinza. In:_____. **Morfologia Matemática: Teoria e Exemplos**. 1996. p. 101-151.
- GONZALEZ, R. C.; WOODS, R. E. **Processamento de Imagens Digitais**. 1.ed. São Paulo: Edgard Blücher Ltda., 2000.
- IBGE. Disponível em: <<http://www.ibge.gov.br/>> Acesso em 27/08/2003.
- JENSEN, J. R. Thematic Information Extraction: Image Classification. In:_____. **Introductory Digital Image Processing**. 2 ed. New Jersey: Prentice Hall, 1996. p. 197-252.
- KARTALOPOULOS, S. V. *Fuzzy Logic*. In:_____. **Understanding Neural Networks and Fuzzy Logic**. 1 ed. Piscataway: IEEE Press, 1996, p. 121-151.
- KLIR, G. J; FOLGER, T. A. **Fuzzy Sets, Uncertainty, and Information**. 1 ed. New Jersey: Prentice Hall, 1988.
- KOK, R.; SCHNEIDER, T; AMMER, U. Object-Based Classification and Applications in the Alpine Forest Environment, **International Archives of Photogrammetry and Remote Sensing**, v. 32, Part 7-4-3 W6, Valladolid, Spain, 3-4 June, 1999.

- KUO, C.; CHOU, T.; LEE, R. Identification of Urban Characteristic Using IKONOS High Resolution Satellite Image. In: **Conferência sobre Sensoriamento Remoto**, 22, 2001, Singapura.
- LILLESAND, T.; KIEFER, R.W. **Remote Sensing and Image Interpretation**. 3.ed. New York: John Wiley & Sons, 1994.
- MAMDANI, E.H.; ASSILIAN, S. , “An experiment in linguistic synthesis with a *fuzzy* logic controller. ,” **International Journal of Man-Machine Studie**, v. 7, n. 1, p. 1-13, 1975.
- MATSUMOTO, E. Y. **MATLAB 6.5 – Fundamentos de Programação**.1. ed. São Paulo: Érica, 2002.
- MELGANI, F.; AL HASHEMY, B.A.R.; TAHA, S.M.R. An Explicit *Fuzzy* Supervised Classification Method for Multispectral Remote Sensing Images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 38, n. 1, p. 287-295, jan. 2000.
- NOVO, E. M. L. M. **Sensoriamento Remoto**. 2.ed. São Paulo: Edgard Blücher Ltda., 1993.
- POLIDORIO, A.M.; IMAI, N.N.; TOMMASELLI, A.M.C.; FLORES, F.C.; FRANCO, C. Realce do Grau de Artificialidade de Feições em Imagens Aéreas Coloridas. **Anais do III Colóquio Brasileiro de Ciências Geodésicas**, p. 1-15, 2003.
- RICHARDS, J. A.; JIA, X. **Remote Sensing Digital Image Analysis - An Introduction**. 3.ed. Berlin: Springer-Verlag, 1999.
- SHACKELFORD, A.K.; DAVIS, C.H. A *Fuzzy* Classification Approach for High-Resolution Multispectral Data Over Urban Areas. IGARSS, **IEEE International Geoscience and Remote Sensing Symposium**, p. 1621-1623, 2002.
- SHAW, I. S.; SIMÕES, M. G. **Controle e Modelagem Fuzzy**. 1.ed. São Paulo: Edgard Blücher Ltda., 1999.
- SCHOWENGERDT, R. A. **Techniques for Image Processing and Classification in Remote Sensing**. London: Academic Press, 1983.
- SPACE IMAGING. Disponível em: <<http://www.spaceimaging.com/>> Acesso em: 10/10/2002
- SUGENO, M. Industrial applications of *fuzzy* control. **Elsevier Science**, 1985.
- ZADEH, L. A. *Fuzzy* Sets. **Information And Control**, v.8, p. 338-353, 1965.
- ZHANG, Y. A spectral and spatial information integrated approach for tree extraction from high-resolution digital imagery. **Digital Earth**, p. 1-10, 2001.
- ZHANG, Y. Texture-Integrated Classification of Urban Treed Areas in High-Resolution Color Infrared Imagery. **Photogrammetric Engineering & Remote Sensing**. v.67, n.12, p. 1359-1365, 2001.

APÊNDICE – RELAÇÃO DOS REGISTROS DE AMOSTRAS DE VERDADE DE TERRENO

AMOSTRAS DE VERDADE DE TERRENO												
No.	Vegetação Arbórea	M/P	Vegetação Rasteira	M/P	Água	M/P	Área Urbana (Telhas)	M/P	Estrada	M/P	Solo Exposto	M/P
01			Saudável e seca	VR/VR			01 Barro marrom 01 Eternit cinza	AU/AU AU/AU			Campo de futebol de areia	AU/AU
02	Árvores de folhas decíduas e perenes	VA/VA	Saudável e seca	VR/VR					Terra	ES/AU		
03							01 Barro marrom	AU/AU				
04	Pinheiro do paraná e outras árvores	VA/VA	Saudável	VR/VR								
05	Árvores	VA/VA							Terra	VR/AU		
06	Pinheiro do paraná e outras árvores	VA/VA	Saudável	VR/VR								
07	Árvores	VA/VA	Saudável e seca	SE/VR					Ferro	ES/AU		
08	Árvores	VA/VA	Saudável e seca	VR/NC					Ferro	ES/AU		
09	Pinheiro do paraná	NC/VA					02 Barro marrom 02 Eternit	AU/AU NC/AU	Terra	NC/AU		
10	Pinheiro do paraná	NC/VA	Gramma	NC/VR			01 Barro marrom 01 Eternit cinza	AU/AU AU/AU				
11	Árvores	VA/VA					01 Eternit cinza 01 Barro marrom 01 Cerâmica laranja	NC/AU NC/AU NC/AU	Terra	ES/ES		
12	Árvores	VA/VA	Gramma	NC/VR			02 Barro marrom	NC/AU				
13	Pinheiro do paraná e outras árvores	NC/VA	Saudável	VR/VR			02 Cerâmica laranja 01 Cerâmica marrom	NC/NC NC/AU				
14	Árvores	VA/VA	Gramma	VR/VR			01 Barro marrom	AU/AU				
15	Pinheiro do paraná e outras árvores	VA/VA	Pastagem Vegetação rasteira seca	VR/VR SE/AU			01 Barro marrom	AU/AU				
16	Pinheiro do paraná e outras árvores	VA/VA	Saudável e seca	VR/VR	Rio	NC/AG			Ferro	ES/ES		
17	Árvores	VA/VA	Gramma	VR/VR								
18							01 Barro marrom	AU/AU			Terreno baldio	SE/NC
19							01 Cerâmica cinza 01 Eternit cinza	AU/AU AU/AU				
20							01 Eternit cinza	AU/AU	02 Asfalto 01 Paralelep ípedo	ES/ES SE/ES AU/ES		
21	Árvores	VA/VA	Saudável	VR/VR			01 Eternit cinza	NC/ES	Terra	NC/AU		
22	Pinheiro do paraná e outras árvores	VA/VA	Saudável	VR/VR					Terra	SE/AU		
23	Árvores	NC/VA	Saudável	VR/VR			01 Barro marrom	NC/AU				
24	Árvores com folhas decíduas e perenes	VA/VA	Pastagem saudável e seca	VR/VR			01 Eternit cinza	SE/AU	Terra	ES/ES		
25			Pastagem Saudável e seca	VR/VR			03 Eternit cinza	NC/AU	Terra	NC/NC		
26			Pastagem Saudável e seca	VR/VR								
27			Saudável	VR/VR			01 Barro marrom	SE/AU				
28							02 Barro marrom	NC/AU	Cascalho	ES/ES		
29							02 Cerâmica vermelha	NC/AU				
30									Terra	ES/AU		

31							01 Cerâmica marrom 01 Cerâmica laranja 01 Eternit cinza	AU/AU NC/AU NC/NC	Cascalho	ES/AU		
32							01 Barro marrom 04 Eternit cinza	NC/AU NC/AU	Cascalho	ES/AU		
33	Árvores	VA/VA					01 Barro marrom	AU/AU	Terra	ES/ES		
34							01 Cerâmica laranja	NC/AU	Terra	ES/AU		
35							03 Barro marrom	AU/AU ES/NC	Cascalho	NC/AU		
36			Saudável	SE/VR					Terra	ES/ES		
37	Pinheiros e árvores com folhas decíduas e perenes	NC/VA	Pastagem saudável e seca	VR/VR			01 Barro marrom	AU/AU				
38			Saudável	NC/VR			01 Barro marrom	ES/AU				
39							02 Barro marrom	ES/AU	Terra (3)	ES/ES ES/ES ES/ES		
40	Árvores	VA/VA	Seca	VR/VR								
41	Pinheiro do paraná e outras árvores	VA/VA	Saudável e seca	VR/VR			03 Barro marrom	NC/AU	Terra (1)	NC/AU		
42									Terra (1)	ES/AU		
43							02 Eternit cinza	NC/AU	Terra	NC/AU		
44							02 Eternit cinza	AU/ES	Terra	ES/ES		
45			Saudável e seca	VR/VR								
46									Anti-pó	ES/ES	Solo exposto	NC/ES
47							01 PVC Colorida	AU/AU				
48							02 Eternit cinza	AU/ES				
49			Saudável e seca	VR/VR					Anti-pó Terra	ES/ES ES/ES	Solo exposto	SE/AU
50							07 Eternit cinza	NC/AU NC/AU	Terra	ES/ES		
51	Árvores	VA/VA	Saudável e seca	VR/VR			03 Eternit cinza	AU/ES SE/AU	Terra	ES/ES		
52							06 Eternit cinza	NC/AU	Terra	ES/ES		
53							04 Eternit cinza	AU/AU	Terra	ES/ES		
54	Árvores	VA/VA	Saudável e seca	VR/VR							Campo de futebol de areia	AU/AU
55							05 Eternit cinza	NC/AU	Terra	NC/AU		
56	Árvores	VA/VA	Saudável e seca	NC/VR							Campo de futebol de areia	AU/AU
57							02 Eternit cinza 01 Barro marrom	NC/AU AU/AU	Terra (2)	ES/ES ES/AU		
58			Saudável e seca	VR/VR					Ferro	ES/ES	Campo de futebol de areia	SE/AU
59			Saudável e seca	NC/VR					Ferro	ES/AU		
60	Árvores de folhas decíduas e perenes	NC/VA	Saudável e seca	VR/VR			01 barro marrom	SE/AU	Ferro	ES/ES		
61			Saudável e seca	VR/VR			03 Barro marrom	NC/AU	Ferro	ES/ES		
62							02 Barro marrom	SE/AU	Asfalto	ES/ES		
63							03 Barro marrom	SE/AU	Terra	AU/ES		
64	Árvores	VA/VA			Rio	AG/AG						
65	Árvores de folhas decíduas e perenes	VA/VA							Asfalto (ponte)	ES/ES		
66	Pinheiro do paraná e outras árvores	VA/VA					01 Cerâmica laranja	NC/AU	Terra	NC/AU		
67	Pinheiros e outras árvores	VA/VA	Gramma	VR/VR			01 Cerâmica vermelha	NC/ES	Paralelepípedo	NC/NC		
68	Pinheiros e outras árvores	VA/VA	Gramma	VR/VR	Rio	NC/AG						
69			Campo de futebol com grama	NC/VR			01 Eternit (cinza).	SE/AU				
70									Asfalto	ES/ES		

71								Asfalto	ES/ES		
72			Gramma	NC/VR			Campo de futebol de concreto	AU/AU		Pequenas porções de solo exposto no meio da grama	SE/AU
73	Pinheiros e outras árvores	SE/VA						Asfalto	ES/ES		
74							01 Barro (marrom)	ES/AU			
75	Árvores decíduas e perenes	VA/VA	Saudável e seca	NC/VR				Terra	AU/ES		
76							01 Metal	AU/AU	Asfalto	ES/ES	
77								Asfalto Ferro	ES/ES ES/ES		
78			Saudável	NC/VR				Asfalto Ponte de concreto	ES/ES ES/ES		
79			Gramma e vegetação rasteira saudável	VR/VR				Ferro	ES/ES		
80			Gramma	VR/VR				Ferro	ES/ES		
81	Árvores	VA/VA						Ferro	ES/AU		
82	Árvores saudáveis e secas	VA/VA	Saudável e seca	NC/VR							
83	Pinheiros do paraná, árvores saudáveis e secas	VA/VA	Saudável e seca	NC/VR							
84	Pinheiros do paraná e outros tipos de árvores	VA/VA	Gramma	VR/VR			Plataforma de concreto Contorno de pedra brita pequena	AU/AU NC/ES			
85			Gramma	VR/VR			01 Eternit cinza	ES/AU	Ferro	ES/ES	
86										Campo de futebol	NC/AU
87	Pinheiros do Paraná	VA/VA	Seca	VR/VR			01 Barro marrom	SE/AU	Rua de paralelep ípedo	ES/ES	
88							01 Cerâmica laranja	AU/AU	Terra	ES/ES	
89							01 Barro marrom 01 Eternit marrom 01 Eternit cinza	NC/ES NC/AU SE/NC			
90	Pinheiros do Paraná	VA/VA	Saudável e seca	VR/VR			01 Barro marrom	SE/AU			
91							01 Barro marrom	AU/AU	a)Paralelep ípedo b)Asfalto	ES/ES ES/ES	
92	Árvores						01 Cerâmica laranja 02 Eternit cinza 01 Barro marrom	AU/AU SE/ES AU/AU	Paralelep ípedo	ES/ES	
93							01 Cerâmica marrom 01 Eternit cinza	NC/AU AU/ES	Asfalto (2)	ES/ES	
94							03 Barro marrom 01 Eternit cinza	NC/AU AU/ES	Asfalto	ES/ES	
95			Saudável e seca	NC/VR			01 Eternit cinza	NC/AU	Terra	ES/AU	
96			Saudável	NC/VR			03 Barro marrom	SE/AU			
97	Pinheiros e outros tipos de árvores	VA/VA	Saudável e seca	VR/VR			01 Barro marrom	SE/AU			
98			Saudável e seca	VR/VR						Solo exposto	SE/ES
99			Saudável e seca	VR/VR					Ponte metálica da linha férrea	ES/ES	
100			Saudável	VR/VR			01 Eternit cinza	AU/AU	Terra	ES/ES	
101							01 Eternit cinza 02 Barro marrom	AU/AU SE/AU	Pedra	ES/ES	
102							01 Barro marrom	SE/NC			
103							01 Barro marrom	NC/AU			

104							02 Barro marrom	AU/AU	Pedra	ES/ES		
105					Rio	AG/AG						
106							01 Eternit cinza	AU/ES				
107									Concreto	ES/ES		
108	Árvores	VA/VA	Gramma	VR/VR								
109	Árvores	VA/VA										
110	Árvores	VA/VA	Saudável	VR/VR					Asfalto	ES/ES		
111	Pinheiros do Paraná e outras árvores	VA/VA	Saudável e seca	VR/VR					Asfalto	ES/ES		
112	Árvores	NC/VA	Saudável e seca	VR/VR								
113	Pinheiros e outras árvores com folhas perenes e decíduas	VA/VA	Saudável	NC/VR					Terra	ES/ES		
114	Pinheiros e outras árvores	VA/VA	Saudável	NC/VR					Terra	ES/ES		
115	Árvores	VA/VA	Gramma	NC/VR			03 Eternit cinza	NC/ES				
116	Pinheiro do paraná e outras árvores de folhas perenes e decíduas	VA/VA	Gramma	VR/VR								
117	Pinheiro do paraná e outras árvores de folhas perenes e decíduas	VA/VA							Estacionamento de anti-pó	ES/ES		
118	Árvores de folhas perenes e decíduas	VA/VA	Gramma	VR/VR								
119	Pinheiros e outras árvores	VA/VA	Gramma	NC/VR								
120	Árvores	VA/VA	Gramma	NC/VR								
121	Árvores saudáveis e secas	VA/VA										
122			Saudável	NC/VR					Asfalto	ES/ES		
123	Árvores de folhas perenes e decíduas	NC/VA										
124	Pinheiros e outras árvores	NC/VA	Saudável e seca	NC/VR								
125							01 Barro marrom	NC/AU	Asfalto	ES/AG		
126							01 Barro marrom	SE/AU				
127			Gramma	NC/VR			04 Cerâmica laranja	NC/AU	Terra	AU/ES		
128	Árvores	NC/VA	Gramma	VR/VR			01 Barro marrom	AU/AU				
129	Árvores						02 Barro marrom	AU/AU	a) Terra	ES/ES		
							01 Eternit cinza	SE/AU	b) Ferro	ES/ES		
130							01 Barro marrom	AU/AU	Asfalto	ES/ES		
							01 Eternit cinza	AU/ES				
131							02 Barro marrom	AU/AU	Asfalto	ES/ES		
132							03 Barro marrom	AU/ES	Asfalto	ES/ES		
133							02 Barro marrom	NC/AU				
134							01 Eternit cinza	AU/ES	Anti-pó	AU/ES		
135							01 Barro marrom	AU/AU				
136							01 Barro marrom	AU/ES				
							01 Eternit cinza	SE/AU				
							01 Cerâmica laranja	ES/ES				
137	Árvore de folhas perenes e decíduas	SE/VA					05 Barro marrom	NC/AU	Ferro	ES/ES		
138	Árvore de folhas perenes e decíduas	VA/VA					03 Barro marrom	NC/AU	Ferro	ES/ES		
139	Árvore de folhas perenes e decíduas	SE/VA					04 Barro marrom	NC/AU	Ferro	ES/ES		
140	Árvores	NC/VA	Saudável e seca	VR/VR			01 Eternit cinza	NC/AU	Terra	NC/ES		
141							02 Barro marrom	NC/AU	Asfalto	ES/ES		
							01 Eternit cinza	AU/AU				
							01 Cerâmica laranja	NC/ES				

Legenda: M/P = Tipo de método utilizado na classificação: Maxver ou Método Proposto.

VA = Vegetação Arborea

SE = Solo Exposto

AU = Área Urbana

NC = Não Classificado

VR = Vegetação Rasteira

ES = Estrada

AG = Água