

ESTUDO DA VIABILIDADE DA CLASSIFICAÇÃO AUTOMÁTICA DE IMAGENS BASEADA EM REGISTROS DIGITAIS E EM INTELIGÊNCIA ARTIFICIAL

Karla dos Santos Teixeira

Dissertação submetida ao corpo docente da Faculdade de Engenharia da Universidade do Estado do Rio de Janeiro – UERJ, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia de Computação – Área de concentração Geomática.

Orientador: Flávio Joaquim de Souza

Co-Orientador: Maria Luiza F. Velloso

Programa de Pós-Graduação em Engenharia de Computação
Área de concentração Geomática

Rio de Janeiro, RJ
Setembro – 2004

FOLHA DE JULGAMENTO

Título: Estudo da viabilidade de uma metodologia para um Sistema de Classificação Automática de Imagens baseada em Registros Digitais e em Inteligência Artificial

Candidato: Karla dos Santos Teixeira

Programa: Pós-Graduação em Engenharia de Computação – Área de concentração Geomática

Data da defesa: 23/09/2004

Aprovada por:

**Orientador: Prof. Flávio Joaquim de Souza, DSc,
UERJ**

**Co-orientador: Prof. Maria Luiza F. Velloso, DSc,
UERJ**

Prof. . Luiz Henrique de Azevedo, DSc, UERJ

Prof. Manoel Gonçalves Rodrigues, Ph.D., UNICAMP

TEIXEIRA, KARLA DOS SANTOS

Estudo da viabilidade da Classificação Automática de Imagens baseada em Registros Digitais e em Inteligência Artificial [Rio de Janeiro] 2004

XI, 89 p. 29,7 cm (FEN / UERJ, M.Sc., Engenharia da Computação – Área de Concentração Geomática, 2004).

Tese – Universidade do Estado do Rio de Janeiro – UERJ.

1. Estudo da viabilidade de uma metodologia para um Sistema de Classificação Automática de Imagens baseada em Registros Digitais e em Inteligência Artificial.

I. FEN/UERJ II. Título (série).

“Devemos julgar um homem mais pelas suas perguntas que pelas respostas”.

Voltaire

“A sutileza do pensamento consiste em descobrir a semelhança das coisas diferentes e a diferença das coisas semelhantes”.

Montesquieu

“So far as the laws of mathematics refer to reality, they are not certain. And so far as they are certain, they do not refer to reality.”

Albert Einstein

“As complexity rises, precise statements lose meaning and meaningful statements lose precision.”

Lotfi Zadeh

"Tentar é arriscar-se ao fracasso. Mas os riscos tem que ser corridos, pois o maior perigo na vida é não arriscar nada."

Leo Buscaglia

Aos meus pais, Helio e Isis, que sempre incentivaram minha carreira profissional e independência.

AGRADECIMENTOS

Aos professores e alunos do Mestrado em Eng. da Computação – Geomática pela oportunidade única de convívio e troca de experiências com as mais variadas áreas de conhecimento (Engenharias – cartográfica, civil, eletrônica e de sistemas – Oceanografia, Biologia, Geografia, Arquitetura e Geologia), o que proporcionou uma importante e significativa ampliação do meu horizonte de estudos.

Ao orientador desta dissertação, Prof. Flávio Joaquim de Souza, pela paciência com que me brindou ao longo de todo o período do desenvolvimento.

Do Departamento de Eng. Cartográfica, da Faculdade de Engenharia (FEN), da Universidade do Estado do Rio de Janeiro (UERJ): ao Prof. Ivan de Araujo Medina, pelo suporte técnico prestado, pela sua indicação deste mestrado e, principalmente, seu incentivo e apoio incondicional, sem os quais não conseguiria terminar esta dissertação; ao Prof. Gilberto Pessanha Ribeiro pelo empréstimo da cena utilizada para teste da metodologia proposta; ao Prof. Luis Henrique Azevedo pela incansável busca por imagens para esta dissertação, bem como pela indicação de pessoas para ajudar no suporte técnico; ao Prof. Jorge Luís Nunes e Silva Brito pelo apoio e opiniões oportunas; e aos demais professores deste departamento pelas valiosas informações e conselhos.

Ao Prof. Kenny Tanizaki-Fonseca, do Instituto de Biologia da UERJ, que permitiu o uso do programa Idrisi32, bem como de seus manuais.

À geógrafa e fotointérprete Maria Elena Ianarelli pelo suporte técnico na parte de interpretação visual das imagens utilizadas – a qual forneceu a verdade terrestre necessária para a real aferição da metodologia proposta, o que implicou na renúncia, por longo período, dos seus tempos de descanso e lazer. A esta profissional competente e figura humana exemplar, o meu preito de eterna gratidão.

Aos alunos do Departamento de Engenharia Cartográfica da UERJ, pela colaboração e tempo pacientemente despendidos no auxílio do desenvolvimento dos conceitos básicos de Engenharia Cartográfica envolvidos nesta dissertação, os quais, de início, pareciam um tanto “esotéricos” para esta engenheira eletrônica.

Ao diretor do Instituto de Pesquisas da Marinha (IPqM) e à chefia do Grupo de Guerra Eletrônica pela oportunidade e confiança.

Aos membros da Banca Examinadora, pela predisposição em analisar este trabalho e pelas sugestões recebidas.

Agradeço a todos os demais que, direta ou indiretamente, colaboraram na elaboração e feitura desta dissertação.

Resumo da Tese apresentada à FEN/UERJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

ESTUDO DA VIABILIDADE DA CLASSIFICAÇÃO AUTOMÁTICA DE IMAGENS BASEADA EM REGISTROS DIGITAIS E EM INTELIGÊNCIA ARTIFICIAL

Karla dos Santos Teixeira

Setembro / 2004

Orientador: Flávio Joaquim de Souza

Co-Orientador: Maria Luiza F. Velloso

Programa de Pós-Graduação em Engenharia de Computação - Área de
Concentração Geomática – Mestrado

Esta dissertação propõe uma metodologia para detecção/reconhecimento automático de padrões em objetos e feições geográficos, baseado na conjunção das técnicas de Análise Espectral, Redes Neurais Artificiais e Lógica Nebulosa, tendo fundamentação nas assinaturas espectrais dos objetos.

Abstract of Thesis presented to FEN/UERJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

FEASIBILITY STUDY OF AN AUTOMATIC IMAGE CLASSIFICATION BASED IN DIGITAL REGISTERS AND ARTIFICIAL INTELIGENCE

Karla dos Santos Teixeira

September / 2004

Advisor: Flávio Joaquim de Souza

Co-Advisor: Maria Luiza F. Velloso

Program Computing Engineering - Geomatic

This work presents a new methodological proposition for automatic pattern detection/recognition in geographic objects and features based in addition of three mainly techniques: Spectral Analysis, Neural Networks and Fuzzy Logic, all of them applied over the objects spectral signatures.

ÍNDICE

ÍNDICE DE FIGURAS XII

ÍNDICE DE TABELAS XIV

ÍNDICE DE SIGLAS XV

1	INTRODUÇÃO	1
1.1	Objetivo	2
1.1.1	Geral	3
1.1.2	Específico	4
1.2	Limitações	4
1.3	Motivação	5
1.4	Histórico	7
1.5	Relevância	9
1.6	Caracterização do Problema	11
2	REVISÃO BIBLIOGRÁFICA	12
2.1	Trabalhos relevantes	12
2.2	Técnicas de Classificação	12
2.2.1	Classificação supervisionada ou assistida	12
2.2.2	Classificação automática ou não supervisionada ou não assistida	13
2.2.3	Classificação híbrida ou semi-automática	13
3	PROGRAMAS COMERCIAIS DE MAIS LARGO EMPREGO	14
3.1	Idrisi32	14
3.2	ENVI	14
3.3	Técnicas de Classificação Automática dos programas	14
3.3.1	IDRISI	14
3.3.2	ENVI	15
3.4	Técnicas de classificação supervisionada dos programas	16
3.4.1	IDRISI	16
3.4.2	ENVI	16
4	BASE DE DADOS	17
4.1	Programa LANDSAT	17
4.2	Cena analisada	19
4.3	Dados e caracterização da cena analisada	21
4.3.1	Geomorfologia e Relevo	21
4.3.2	Clima	22
4.3.3	Hidrografia	22
4.3.4	Vegetação	23
4.4	Definição das classes em estudo	23
4.5	Correção das Distorções Geométricas e Radiométricas	25
4.6	Comportamento espectral de alvos	25
4.7	Recursos utilizados	27
4.8	Imagens para teste de parte da metodologia proposta	27
4.9	Classificações disponibilizadas pela fotointérprete	29
4.10	Análise das classificações realizadas pelos programas analisados	31
4.10.1	Classificação não supervisionada no IDRISI	32
4.10.1.1	CLUSTER	32

4.10.1.2	ISOCLUST	34
4.10.2	Classificação supervisionada no IDRISI – MAXLIKE	36
4.10.3	Classificação não supervisionada no ENVI	40
4.10.3.1	ISODATA	40
4.10.3.2	K-MEANS	41
4.10.4	Classificação supervisionada no ENVI – MAXVER	43
5	METODOLOGIA	46
5.1	Análise Espectral	46
5.2	Breve introdução a Lógica Nebulosa	48
5.3	Metodologia Proposta	48
5.4	Desenvolvimento do módulo Lógica Nebulosa	51
6	RESULTADOS OBTIDOS	57
6.1	Classificações Obtidas	57
6.2	Análise Qualitativa dos Resultados	58
7	CONCLUSÕES	61
7.1	Recomendações	61
8	REFERÊNCIAS BIBLIOGRÁFICAS	63
 ANEXO		 72
Conceitos Básicos Utilizados		72

ÍNDICE DE FIGURAS

FIGURA 1	– Grade de localização do LANDSAT 5 e 7 para o Estado do Rio de Janeiro (a cena utilizada está destacada na cor rosa).....	20
FIGURA 2	– Composição RGB 321 da cena utilizada.....	21
FIGURA 3	– Recorte 1 - Marambaia (composição 453).	28
FIGURA 4	– Recorte 2 - Pedra de Guaratiba (composição 543).	28
FIGURA 5	– Composição falsa-cor 321 recorte Marambaia.....	29
FIGURA 6	– Composição falsa-cor 321 recorte Pedra de Guaratiba.	30
FIGURA 7	– Classificação visual do recorte Marambaia.....	30
FIGURA 8	– Classificação visual do recorte Pedra de Guaratiba.	31
FIGURA 9	– Classificação IDRISI-CLUSTER, ajuste fino, composição 453, para o recorte Marambaia.	33
FIGURA 10	– Classificação IDRISI-CLUSTER, ajuste fino, composição 453 para o recorte Pedra de Guaratiba.....	33
FIGURA 11	– Classificação IDRISI-ISOCLUST, 10 iter., para o recorte Marambaia (semente 453).	34
FIGURA 12	– Classificação IDRISI-ISOCLUST, 50 iter., para o recorte Marambaia (453).....	35
FIGURA 13	– Classificação IDRISI-ISOCLUST, 10 iter., para Pedra Guaratiba (453).	35
FIGURA 14	– Classificação IDRISI-ISOCLUST, 50 iter., para o recorte Pedra de Guaratiba (semente 453).	36
FIGURA 15	– Classificação MAXLIKE com uma amostra para o recorte Marambaia.	37
FIGURA 16	– Classificação MAXLIKE com três amostras para o recorte Marambaia.	37
FIGURA 17	– Classificação MAXLIKE com sete amostras para o recorte Marambaia.	38
FIGURA 18	– Classificação MAXLIKE com sete amostras para o recorte Pedra de Guaratiba.....	39
FIGURA 19	– Classificação ENVI-ISODATA, 50 iter. CH zero, para o recorte Pedra de Guaratiba (composição 453).....	40
FIGURA 20	– Classificação ENVI-ISODATA, 50 iter. CH zero, para o recorte Marambaia (composição 453).....	41
FIGURA 21	– Classificação ENVI-K_MEANS, 50 iter. CH zero, para o recorte Pedra de Guaratiba (composição 453).....	42
FIGURA 22	– Classificação ENVI-K_MEANS, 50 iter. zero para o recorte Marambaia (composição 453).....	42
FIGURA 23	– Classificação MAXVER com uma amostra para o recorte Pedra de Guaratiba.....	43
FIGURA 24	– Classificação MAXVER com três amostras para o recorte Pedra de Guaratiba.....	43

FIGURA 25	– Classificação MAXVER com sete amostras para o recorte Pedra de Guaratiba.....	44
FIGURA 26	– Classificação MAXVER com sete amostras para o recorte Marambaia.....	45
FIGURA 27	– Exemplo de uma quantização dos vizinhos imediatamente adjacentes.....	46
FIGURA 28	– Visualização aproximada dos conjuntos de treinamento (pontos em vermelho), que se encontram fora das áreas dos recortes (retângulos brancos).....	47
FIGURA 29	– Estrutura proposta para um classificador automático.....	48
FIGURA 30	– Modelo implementado no módulo <i>Fuzzy</i> do MATLAB.....	51
FIGURA 31	– Tela de entrada do módulo MLN implementado.....	52
FIGURA 32	– Telas das funções de pertinência de entrada do MLN relativas as bandas 1, 2 e 3.....	53
FIGURA 33	– Telas das funções de pertinência de entrada do MLN relativas as bandas 4, 5 e 7.....	54
FIGURA 34	– Tela da função de saída do MLN implementado.....	55
FIGURA 35	– Exemplo da tela das funções de pertinência de entrada para a banda 4, com detalhe para os parâmetros da função Agua4.....	55
FIGURA 36	– Resultado da classificação digital (saída do MLN implementado) do recorte Marambaia.....	57
FIGURA 37	– Resultado da classificação digital (saída do MLN implementado) do recorte Pedra de Guaratiba.....	57
FIGURA 38	– Classificação visual (a) e a classificação digital (b) do recorte Marambaia.....	58
FIGURA 39	– Classificação visual (a) e a digital (b) do recorte Pedra de Guaratiba.....	58

ÍNDICE DE TABELAS

TABELA 1	– Satélites do programa LANDSAT e respectivos sensores embarcados.....	18
TABELA 2	– Resultados da classificação MAXLIKE, com 7 amostras, para o recorte Marambaia.....	38
TABELA 3	– Resultados da classificação MAXLIKE, com 7 amostras, para o recorte Pedra de Guaratiba.....	39
TABELA 4	– Resultados da classificação MAXVER, com 7 amostras, para o recorte Pedra de Guaratiba.....	44
TABELA 5	– Resultados da classificação MAXVER, com 7 amostras, para o recorte Marambaia.....	45
TABELA 6	– Exemplo do conjunto de treinamento.....	47
TABELA 7	– Resultados da classificação obtida para o recorte Marambaia.	59
TABELA 8	– Resultados da classificação obtida para o recorte Pedra de Guaratiba.	59
TABELA 9	– Acertos obtidos pelo MLN e pelo ENVI (MAXVER).	60

ÍNDICE DE SIGLAS

AE	Análise Espectral
BMP	BitMaP
CDA	Classificação Digital Automática
ENVI	<i>Environment for Visualizing Images</i>
EUA	Estados Unidos da América do Norte
GeoTIFF	<i>Geographic Tagged Image File Format</i>
IA	Inteligência Artificial
IBGE	Instituto Brasileiro de Geografia e Estatística
INPE	Instituto Nacional de Pesquisas Espaciais;
LN	Lógica Nebulosa (<i>Fuzzy Logic</i>)
NASA	<i>National Administration Space Agency</i>
ONU	Organização das Nações Unidas
PDI	Processamento Digital de Imagens
RGB	<i>Red – Green – Blue</i> (Vermelho – Verde – Azul)
RNA	Redes Neurais Artificiais (<i>Artificial Neural Networks</i>)
SE	Sistemas Especialistas
SIG	Sistemas de Informações Geográficas
SPRING	Sistema de PRocessamento de Informações Georeferenciadas
SR	Sensoriamento Remoto
USGS	<i>United States Geological Survey</i>

1 INTRODUÇÃO

Definições metodológicas voltadas para a detecção ou o reconhecimento automático de padrões de objetos ou feições geográficas, com base em registros digitais colhidos por plataformas orbitais, constituem, hoje, uma ampla base de investigação científica.

A presente construção de um analisador inteligente trata de uma proposta metodológica que, após o estágio inicial de aprendizagem, realizará detecção automática de padrões a partir, somente, de registros digitais gerados por sensores ópticos instalados em satélites artificiais ou aerotransportados. Tal metodologia engloba, essencialmente, princípios de Análise Espectral (AE) e de Inteligência Artificial (IA), sendo esta última representada pelas Redes Neurais Artificiais (RNA) e pela Lógica Nebulosa (LN).

Uma área-teste – situada no centro-sul do Estado do Rio de Janeiro – que dispusesse de cena com todas as suas bandas espectrais, obtida por sensor óptico instalado em plataforma orbital (LANDSAT7), foi escolhida, tendo em vista a diminuição tempo-custo no estabelecimento da verdade terrestre, para a prototipagem da metodologia proposta.

Devido à média resolução (30 metros) do sensor orbital utilizado, as classes sobre as quais se apoiou a presente investigação são as de Água, de Área Florestal e de Área Construída. Tais classes estão englobadas pelo sistema padronizado de Classificação do Uso da Terra e do Revestimento do Solo para Utilização com Dados de Sensores Remotos, do *United States Geological Survey* (USGS), que é empregado pelo Instituto Brasileiro de Geografia e Estatística (IBGE) [3]. Para uma verificação mais robusta da viabilidade da metodologia preconizada, foi adicionada uma sub-classe, Mangue, interseção de duas classes – Água e Terra Úmida [57].

A implementação foi realizada em ambiente MATLAB / WINDOWS, uma vez que atende aos critérios do estudo de viabilidade.

A metodologia proposta engloba, essencialmente, princípios de Análise Espectral (AE), Rede Neural Artificial (RNA) e Lógica Nebulosa (LN).

Esta dissertação é dividida nos seguintes capítulos:

- 1) INTRODUÇÃO: são descritos os objetivos, o geral e os específicos, bem como as motivações da dissertação, um breve histórico sobre as inter-relações do Processamento Digital de Imagens (PDI) e o

Sensoriamento Remoto (SR), a suposta relevância deste trabalho e a caracterização do problema de classificação automática em imagens adquiridas por sensores ópticos.

- 2) REVISÃO BIBLIOGRÁFICA: são apresentadas as principais publicações acerca de Reconhecimento de Padrões, de SR, de PDI, de RNA e de LN, bem como um resumo das técnicas de classificação.
- 3) PROGRAMAS COMERCIAIS DE MAIS LARGO EMPREGO: pequena resenha acerca das técnicas empregadas em classificação automática por alguns dos programas comerciais mais utilizados.
- 4) BASE DE DADOS: onde são expostos os dados relevantes e a caracterização da cena utilizada na análise da metodologia proposta.
- 5) METODOLOGIA: consiste da apresentação da análise espectral realizada, da metodologia proposta propriamente dita, de uma breve introdução à LN e a descrição do desenvolvimento do Módulo de Lógica Nebulosa (MLN) implementado.
- 6) RESULTADOS OBTIDOS: descrição das classificações obtidas e análise qualitativa dos resultados, como também do desempenho da metodologia proposta.
- 7) CONCLUSÕES: inferências e proposições feitas com base nos resultados obtidos.
- 8) RECOMENDAÇÕES: são expostas as propostas de trabalhos futuros.
- 9) REFERÊNCIAS BIBLIOGRÁFICAS: onde são mencionadas as publicações, artigos, trabalhos, teses, páginas na Internet, dentre outros, citadas neste trabalho.
- 10) ANEXO: são apresentados os conceitos básicos utilizados na dissertação.

1.1 OBJETIVO

Estudo da viabilidade de detecção automática de padrões nos registros obtidos por sensores ópticos digitais multiespectrais, embarcados em plataformas orbitais ou aerotransportados, com base em técnicas de Inteligência Artificial.

1.1.1 GERAL

A proposta da metodologia é a de alcançar determinação automática de padrões em cenas multiespectrais que pode se “especializar” naquelas classes de interesse do usuário: isto ocorre na medida em que a base de dados é ampliada através da análise e aprendizagem adquirida com a entrada de novos dados (registros digitais) relativos aos alvos de interesse.

Os tipos de padrões detectáveis dependem somente do conhecimento acumulado existente no sistema. Assim sendo, todo tipo de padrão – seja terrestre, marítimo, aéreo ou espacial – que possua, necessariamente, registros digitais multiespectrais – poderá ser detectado com esta metodologia, servindo tanto para fins de estudo e pesquisa, quanto para fins comerciais e militares de assinaturas espectrais de alvos, desde que as classes definidoras dos temas de interesse do usuário sejam introduzidas previamente.

Está previsto, também, que os alvos não reconhecidos pelo sistema serão objeto de relatório, de modo a permitir ao usuário a criação de novas classes, se assim o desejar.

A abrangência deste estudo compreende as diversas áreas contempladas pelo SR, tais como:

- Geologia: prospecção e levantamento de potencialidades do solo (mineral e petróleo);
- Geografia: levantamento e monitorização de recursos naturais e antrópicos;
- Engenharia Cartográfica: atualização cartográfica de mapas e cartas; delimitação de áreas;
- Engenharia Civil: delimitação de corpos d'água e de represas e hidrelétricas;
- Engenharia de Telecomunicações: base de dados para telefonia;
- Administração: atualização e planejamento de cadastro urbano, rural e ambiental;
- Agricultura: previsão de safras e agricultura de precisão;
- Pecuária: manejo de pastagens e pecuária de precisão;
- Climatologia: previsão de tempo; e

- Defesa: levantamento espacial multifinalitário do território nacional, ampliação dos polígonos de defesa, controle do tráfego marítimo oceânico.

1.1.2 ESPECÍFICO

Análise dos resultados obtidos na prototipagem do estudo proposto, no que se refere à qualidade alcançada na identificação de padrões nas classes de Água, de Área Florestal, de Área Construída e Mangue.

Estas quatro classes foram escolhidas devido a:

- a) pertencerem as classes mais comumente utilizadas na maioria das classificações, em solo brasileiro;
- b) serem classes diferentes entre si, abrangendo o sistema padronizado de Classificação do Uso da Terra e do Revestimento do Solo para Utilização com Dados de Sensores Remotos, do USGS, definido por [3], e adotado pelo IBGE; e
- c) serem classes perceptíveis na interpretação visual.

Este trabalho teve a preocupação primordial de testar a validade da hipótese da correlação entre as assinaturas espectrais com base em técnicas de Inteligência Artificial, já que estas proporcionam aprendizagem de conhecimentos à medida que novos dados são inseridos para avaliação. A interferência humana ocorre somente ao final do processo quando o usuário pode corrigir os resultados apresentados, se assim o desejar, o que irá proporcionar um aprendizado constante.

1.2 LIMITAÇÕES

Inicialmente, pretendia-se testar esta metodologia com as imagens advindas dos satélites LANDSAT, IKONOS e CBERS.

Para tanto, é necessária a disponibilidade das cenas com todas as suas bandas espectrais correspondentes. Entretanto, o satélite CBERS1 apresentou problemas de calibração em radiometria, com erro aleatório, o que inviabiliza o seu uso nesta metodologia essencialmente calcada em valores espectrais.

Houve a disponibilização das cenas do CBERS-2, mas esta ocorreu em tempo não hábil para a sua implementação na metodologia proposta.

Devido à grande dificuldade encontrada na aquisição ou cessão das imagens do IKONOS necessárias para teste e validação da metodologia,

principalmente no tocante à disponibilidade das cenas com todas as suas bandas espectrais, só foi possível a implementação sobre cenas do satélite LANDSAT.

Idealmente, como condições básicas e mínimas, para obtenção de uma verificação satisfatória da metodologia, estabeleceu-se que seria necessário a utilização de, ao menos, quatro conjuntos de cenas que possuísem as classes em estudo, abarcando as quatro estações do ano, sendo que cada conjunto deveria observar, na pior hipótese, duas épocas diferentes. Mas, lamentavelmente, só foi possível obter, com gratuidade, uma cena com todas as bandas, em uma única época.

1.3 MOTIVAÇÃO

Da literatura existente – como em [9], [11], [17], [18], [35], [36], [44] e [59] – depreende-se que a análise e a interpretação de uma imagem multiespectral necessita de intérpretes especializados nos diversos temas presentes. Isto significa, invariavelmente, numerosas horas de aplicação, bem como de probabilidade, para a concordância entre os resultados obtidos por intérpretes diferentes, sobre áreas não analisadas nas suas verdades terrestres na ordem de 68%; o que gera inconvenientes de toda ordem, os quais irão se manifestar, de forma contundente, quando da renovação das equipes de intérpretes. Sobre o 1/3 restante recaem diversas dúvidas, dirimidas, somente, com o concurso do levantamento da verdade terrestre.

As classificações automáticas (ou não supervisionadas, ou não assistidas) tendem, na medida em que aumentam sua base de conhecimento, a:

- Diminuir, progressivamente, a intervenção dos intérpretes especializados;
- fornecer, em um prazo razoavelmente curto, uma visão global das classes de objetos geográficos contidas no classificador;
- não demandar usuários experientes no uso corrente do sistema computacional utilizado para a classificação;
- não implicar em perdas de tempo decorrentes de uma série de tentativas de compatibilização dos parâmetros necessários para a interpretação visual da imagem (realce de contraste e transformação IHS, principalmente) [18]; e
- também não acarretar em dispêndio de grande tempo de processamento computacional necessário para edição ou calibração de

amostragens conforme exigido pelos programas comerciais de classificação semi-automática ou supervisionada.

Tudo isto leva à indução de que a classificação automática possui vantagens que não podem ser desconsideradas, a despeito de suas principais desvantagens, tais como: requerer tempo tanto para a repetitividade conveniente da tomada das cenas quanto para o treinamento da RNA. Por outro lado, a existência de diversos métodos de classificação não supervisionada em variados programas presentes no mercado traz confusão e desconfiança, quando da proposta de uma nova metodologia automática, devido à grande maioria destes serem “engessados” e por não possuírem opção de expansão e aprendizado das suas bases de conhecimento.

A classificação supervisionada (ou assistida), por sua vez, é amplamente utilizada por permitir que o usuário interfira em todo o processo de decisão. Apresenta, entretanto, alguns inconvenientes: os programas exigem, previamente, a indicação de amostras das classes desejadas para a realização da classificação; a classificação realizada, geralmente, é baseada em simples comparações espectrais, usualmente sobre fusão de três bandas, podendo ser alterada de acordo com as exigências do usuário; quanto mais complexa for a classificação, mais demorado será todo o processo, por exigir variadas e consecutivas pré-classificações até se obter uma classificação satisfatória final; o usuário, necessariamente, terá que ser um especialista na área em análise (ou possuir uma equipe de especialistas), além de possuir conhecimentos técnicos em interpretação visual e em processamento de imagens, de modo a realizar uma classificação satisfatória; os métodos de classificação supervisionada exigem tempo para estudos, testes e verificações na busca daquele mais favorável para uma determinada classe de objetos geográficos.

Assim sendo, a grande desvantagem da classificação supervisionada é que esta despende um tempo computacional operativo e de pessoal especializado enorme, além de gerar incertezas acerca da classificação realizada; não sendo comum a feitura de histórico que explique, detalhadamente, as diretrizes da classificação realizada, os métodos empregados, nem as alterações feitas – o que irá gerar, por vezes, sérios problemas operacionais, quando da substituição ou reposição de pessoal.

Pesquisando junto às organizações que, no Brasil, fornecem produtos derivados de imageadores orbitais multiespectrais, constata-se que o grosso da demanda (mais de 98%) se dá sobre cópias em papel e arquivos digitais de fusões em

falsa-cor (notadamente 345 e 543). O uso dos registros digitais, banda a banda, é, praticamente, inexistente.

As técnicas de classificação digital têm pouca utilização no nosso país [2] devido a conjugação de diversos fatores: a necessidade de requisitos mínimos computacionais, que exigem alta capacidade de armazenamento, um grande banco de dados e processamento deste grande volume de dados; o dispêndio de tempo com treinamento e a especialização do usuário; o estudo das técnicas mais utilizadas, bem como o de tecnologias futuras de forma a se determinar suas rotinas de correção de erros. Tudo isto implica num alto investimento de capital inicial e coleta de resultados, efetivamente operacionais, em prazos dilatados.

Cabe ressaltar que os programas comerciais existentes, bem como as metodologias utilizadas para a classificação automática de padrões em imagens multiespectrais, são todos frutos de conhecimento estrangeiro, que as detém, sem explicá-las totalmente. O único expoente nacional é o programa SPRING – Sistema de processamento de Informações Georeferenciadas, fruto da pesquisa do Instituto de Pesquisas Espaciais (INPE), de São José dos Campos, São Paulo. Este é um programa livre, podendo ser copiado da página da Internet do INPE [29]. Ocorre que o SPRING, apesar da sua notória qualidade, não trouxe nenhuma inovação na área de classificação automática de padrões, e por isso não foi utilizado nesta proposta.

Após todas estas considerações concluiu-se que uma metodologia que permita detecção automática de alterações em objetos geográficos com uma margem de incerteza, pelo menos, igual a de um intérprete, com o dispêndio de um tempo computacional razoavelmente inferior e a utilização de recursos computacionais medianos, será de grande valia para a maioria dos usuários de imagens multiespectrais. O ciclo investigativo que ora se inicia, caminha no sentido do atendimento dessa constatação.

1.4 HISTÓRICO

Os dados obtidos por sensoriamento remoto, notadamente aqueles detectados por plataformas orbitais, impactaram, com diversas profundidades e extensões, variadas áreas do conhecimento, exigindo, no mais das vezes, intervenções multidisciplinares.

Os satélites artificiais permitiram a demonstração de uma das leis da Física Moderna: a observação varia de acordo com o referencial adotado. E este novo referencial, apresentado pelos satélites, o de uma visão verdadeiramente espacial,

proporciona visões multiespectrais, sinópticas e multitemporais da superfície terrestre, inclusive dos fenômenos culturais que nela ocorrem.

As imagens obtidas por dados advindos de sensores necessitam ser lidas e interpretadas por especialistas, os quais são especialistas na análise de um determinado tema, a partir de chaves de interpretação assistida, baseadas em modelos de correlação com a verdade terrestre.

A interpretação visual é um processo lento, e a formação do intérprete exige vários anos de árduo aprendizado e estudo, marcado por uma alta subjetividade – imposta pela interação entre o padrão da imagem, o olho do observador, o seu conhecimento específico relativamente ao tema pesquisado e a sua sensibilidade para as diversas nuances passíveis de ocorrer; o que acarreta imprecisões diretamente proporcionais à mixagem de padrões de imagem, tal como ocorre, por exemplo, em áreas de transição e em culturas combinadas.

O advento de ferramentas computacionais mais rápidas, com maior poder de armazenamento, e mais eficientes, aliado ao avanço dos estudos de PDI e de algoritmos baseados em IA proporcionaram a disponibilidade, ao público em geral, de classificadores não-supervisionados a partir de meados da década de 1990. Estes classificadores possibilitaram a monitorização (em nível macro) de áreas, principalmente as ermas e as de difícil acesso, de uma forma mais rápida e sem a premente necessidade de ida ao campo.

Cabe ressaltar que tais classificadores utilizam análises menos pormenorizadas, pois sua principal vantagem é a de proporcionar uma macro-visão da cobertura e do uso do solo da região, no menor tempo possível. Assim, o que antes era feito por uma equipe de interpretadores, de forma visual e manual, sendo, portanto, um processo artesanal e demorado, hoje pode ser realizado por um único microcomputador, e numa ínfima fração do tempo utilizado.

O surgimento das técnicas de PDI, o desenvolvimento da Eletrônica Digital e o avanço da tecnologia dos sensores orbitais e aerotransportados (que deu início à produção e disponibilização de uma grande, e sempre crescente, massa de registros) transformaram o SR num recurso imprescindível aos levantamentos cartográficos e aos inventários de recursos naturais, bem como a qualquer outra atividade que utilize a informação geográfica. Como tal informação é praticamente indispensável em qualquer atividade econômica, política, social e, até mesmo, cultural, não é de se admirar tamanha aceitação e utilização das imagens orbitais. Esta difusão proporcionou um impulso extra na pesquisa e desenvolvimento do PDI, formando uma

nova ramificação de suas técnicas: aquelas voltadas especificamente para o processamento de imagens obtidas através de sensores instalados em plataformas orbitais.

Assim, estas sempre crescentes necessidades e massas de dados, exigem, como prerrogativas prementes e indispensáveis à utilização da tecnologia do SR, o emprego de ferramentas inteligentes de análise que dispensem a intervenção humana, ou que a reduzam a um mínimo.

É crescente o desenvolvimento e a aplicação de técnicas de localização geográfica em diversos segmentos da sociedade, como no rastreamento de meios de transporte e de pessoas. Tais técnicas aliadas ao SR proporcionam uma ferramenta poderosíssima na comprovação da verdade terrestre de feições e objetos geográficos, após, ou no transcurso, de estudos baseados em imagens de satélite.

Até pouco tempo existia, somente, a dicotomia dado geográfico e informação geográfica – a informação derivava da análise de variados dados. Agora surge um novo conceito: o conhecimento geográfico, que é aquele derivado da conjunção de dados geográficos, informações geográficas e técnicas de IA. Não basta somente adquirir dados e deles extrair informações: é necessário o entendimento amplo das diversas técnicas, e a integração de metodologias e tecnologias envolvidas no processo, de forma a se atingir a holística necessária. Assim, tem-se agora uma nova tríade: dado – informação – integração.

A IA é uma ciência que visa o desenvolvimento de algoritmos e técnicas destinados à emulação dinâmica dos processos de obtenção, memorização, conceituação, compreensão, criação, distinção, inferência, adaptação, aprendizagem, interpretação e aplicação, de forma a se obter como resultado uma simulação do conhecimento humano.

A tecnologia baseada em IA tornou possível para as máquinas a realização de tarefas complexas, tediosas, altamente consumidoras de tempo, insalubres ou inseguras sem a presença do homem, proporcionando, desta forma, o aumento da eficiência através da interação com procedimentos automatizados.

1.5 RELEVÂNCIA

Pelo até aqui exposto, depreende-se que uma metodologia que agregue classificação automática com análises conjugadas de várias classes é de grande valia para o usuário, principalmente aquele que necessite de uma rápida e aceitável classificação de registros orbitais.

As atualizações cadastrais, as atividades de inventário, o estudo de impactos ambientais, bem como a monitorização temática do meio ambiente – rural, urbano, hidrográfico, geológico, dentre vários outros – são processos que requerem uma ferramenta computacional rápida e eficiente. Tais processos encontram no reconhecimento de padrões um meio que permite uma destacada aplicação, tornando-o, por conseguinte, numa ferramenta importante na tomada de decisão e no estabelecimento das ações indicadas.

A rapidez na monitorização de áreas tem vital importância em diversas aplicações, como acompanhamento de queimadas, de desmatamentos, do processo de desertificação, na defesa civil, no fornecimento de dados para sistemas de previsão de cheias, na previsão de safras agrícolas e naquelas de Defesa e Segurança (Forças Armadas e Polícia Federal).

Não pode ser esquecido que a automatização do reconhecimento de padrões implica numa execução sem interrupções causadas pela fadiga, estresse ou cansaço como as que ocorrem quando seres humanos estão diretamente envolvidos. Tal fato gera benefícios como uma maior velocidade e uma melhor uniformidade do padrão de qualidade de execução de tarefas que são essenciais para a tomada de decisão. O que falta ao computador é a introdução do conhecimento humano adquirido pelos expertos e das correlações possíveis, que se traduzem pelas técnicas de IA.

As dimensões continentais do Brasil aliadas às suas poucas explorações, mapeamentos e cadastramentos, além dos grandes e extensivos recursos naturais existentes, exigem uma monitorização constante de seu território. Isto só é possível com a utilização de sistemas de apoio baseados em alta tecnologia, que irão nortear a tomada de decisão mais acertada para supervisão e patrulhamento do território brasileiro, com o objetivo precípuo de preservação de sua soberania e de suas riquezas. O desenvolvimento desta metodologia, fruto de pesquisa nacional, pode fornecer uma possível solução para tal lacuna, assegurando a independência tecnológica do país neste âmbito: questão extremamente importante em relação a soberania nacional, principalmente porque o atual tema acerca da Defesa Nacional envolve a Amazônia, área muito visada por interesses multinacionais. Mais evidencia a relevância desta metodologia quando se considera que os sistemas de classificação automática existentes, em realidade, são sistemas semi-automáticos (necessitando de expertos nas classes ou alvos em estudo), e todos estrangeiros, além de serem extremamente dispendiosos em tempo e em custos.

A utilização desta metodologia com a tecnologia dos Sistemas de Informação Geográfica (SIG) irá permitir uma maior rapidez de monitorização da superfície terrestre, principalmente com a entrada no mercado das imagens orbitais de alta e média resolução espacial (IKONOS, QUICKBIRD e SPOT5) e espectral (EO-1 e AVIRIS). Esta nova gama de sensores permitirá o estudo mais a fundo das assinaturas espectrais de alvos específicos.

1.6 CARACTERIZAÇÃO DO PROBLEMA

O reconhecimento de padrões multiespectrais é um processo que abarca, além da detecção e do tratamento do sinal (radiação eletromagnética) em si, a identificação e a classificação das alterações de estado observadas em uma classe composta por diversos objetos geográficos, através de tomadas diferidas no tempo. Logo, este processo se torna extremamente complexo na medida em que mais classes são agregadas.

O ponto fundamental pertinente é como tal reconhecimento será detectado, modelado, classificado e representado, de forma a se obter um resultado que seja o mais próximo possível da verdade terrestre.

A metodologia proposta nesta dissertação pretende obter resultados mínimos de 68% de acertos, o que já a situaria no patamar de precisão alcançado por especialistas nas classificações visuais realizadas sobre áreas desconhecidas.

2 REVISÃO BIBLIOGRÁFICA

Primeiramente, são indicados os trabalhos e livros relevantes nas áreas de SR, PDI, e Classificação de Padrões. Por último, efetua-se uma descrição das técnicas mais utilizadas em classificação automática.

2.1 TRABALHOS RELEVANTES

Destaco como os trabalhos mais relevantes, na área de classificação automática de imagens multiespectrais os de [67] e [33].

Os trabalhos que considero mais relevantes utilizando técnicas de IA são os de [49], [70], [50], [8], [20] e [19].

2.2 TÉCNICAS DE CLASSIFICAÇÃO

A classificação digital de uma imagem multiespectral consiste na utilização de técnicas que irão proporcionar a identificação e a distribuição em classes dos dados contidos nos registros digitais, segundo um determinado ordenamento ou método, possuindo por objetivo principal “a substituição da análise visual de dados de uma imagem através de uso de técnicas quantitativas que automatizem a identificação de feições em uma cena. Este processo geralmente envolve a análise de dados multiespectrais e a aplicação de regras de decisão baseadas em estatística para a determinação da identidade da cobertura terrestre de cada *pixel* em uma imagem” [35].

“Quando as regras de decisão são baseadas somente nas radiâncias espectrais observadas, o processo de classificação é chamado de reconhecimento de padrões espectrais” [35]. Por outro lado, as regras de decisão podem ser baseadas em figuras geométricas, medidas e padrões, sendo este procedimento chamado de reconhecimento de padrões espaciais. Em ambos os casos, todos os *pixels* de uma imagem serão categorizados em temas (grandes classes) [64].

2.2.1 CLASSIFICAÇÃO SUPERVISIONADA OU ASSISTIDA

Neste tipo de classificação o usuário irá “supervisionar” ou “assistir” o processo de categorização dos *pixels* através da especificação – de acordo com o algoritmo utilizado – dos descritores numéricos dos vários tipos de ocorrências presentes na cena em análise. Para tal, são estipuladas áreas de teste (ou de amostra) a fim de compilar a “chave” de interpretação numérica que define a assinatura espectral de cada tipo de feição de interesse. Assim, a quantização de

cada *pixel* será comparada, em termos numéricos, com cada categoria criada pelo usuário e “rotulada” como pertencente à categoria que “seja mais apropriada” (esta rotulação será de acordo com o algoritmo utilizado) [64].

Logo, o usuário dispõe de informações (amostras) que identificam cada classe de interesse [27].

2.2.2 CLASSIFICAÇÃO AUTOMÁTICA OU NÃO SUPERVISIONADA OU NÃO ASSISTIDA

Nesta abordagem os *pixels* de uma imagem são, primeiramente, classificados através da agregação destes em agrupamentos espectrais próprios (*clusters*), determinados somente pelas funções matemáticas descritoras das propriedades inerentes às classes pesquisadas. Assim, o reconhecimento das classes presentes na imagem é feito somente pelo algoritmo, que irá agrupar os pixels em categorias de assinaturas parecidas, não havendo intervenção humana durante seu processo [27]. Cabe ao usuário identificar que tipo de cobertura efetivamente aquelas categorias representam [14].

Tal classificação é utilizada quando não se conhece a região em estudo, e se necessita de uma identificação rápida da área.

2.2.3 CLASSIFICAÇÃO HÍBRIDA OU SEMI-AUTOMÁTICA

Esta é uma fusão das técnicas de classificação não supervisionada com as de classificação supervisionada. Este tipo de classificação, por apresentar resultados finais mais condizentes com a verdade terrestre (em relação a não supervisionada) e em menos tempo, que a supervisionada, é a mais utilizada atualmente.

3 PROGRAMAS COMERCIAIS DE MAIS LARGO EMPREGO

Os programas Idrisi32 e o ENVI foram criticados a fim de se ter uma base do estado-da-arte, em termos comerciais, das técnicas utilizadas na classificação automática de imagens. Serão destacadas suas principais vantagens e desvantagens somente acerca destas técnicas, pois demais considerações fogem do escopo deste estudo.

Estes programas foram escolhidos por serem os mais utilizados pelos pesquisadores e profissionais do ramo do Sensoriamento Remoto por possuírem módulos de classificação automática – que exigem um mínimo conhecimento de utilização de computador por parte do usuário, bem como de classificação de imagens – e por estarem disponíveis para teste.

3.1 IDRISI32

O IDRISI (nome em homenagem ao famoso cartógrafo e geógrafo árabe Abou Allah Mohammad al-Idrisi, que viveu no século XII), versão 32 *bits*, *release 2*, do *Clark Labs* da Universidade de Clark, em Massachussets, nos Estados Unidos da América do Norte (EUA), por ser um dos programas mais utilizados por pesquisadores [64].

3.2 ENVI

O ENVI (*Environment for Visualizing Images*), versão 3.6, da *Research Systems*, no Colorado, EUA, é considerado, por muitos, como um dos melhores programas comerciais de PDI disponíveis no mercado, e utilizado por diversas instituições brasileiras, como a Companhia de Pesquisa de Recursos Minerais (CPRM), a Universidade de São Paulo (USP), a Universidade de Campinas (UNICAMP) e o Instituto Nacional de Pesquisas Espaciais (INPE) [64].

3.3 TÉCNICAS DE CLASSIFICAÇÃO AUTOMÁTICA DOS PROGRAMAS

3.3.1 IDRISI

Possui dois módulos de classificação não supervisionada: CLUSTER e ISOCLUST.

A técnica utilizada no CLUSTER consiste na seleção pelo pico de histograma (que é definido como um valor de frequência maior que os adjacentes): é realizada uma busca por todo o histograma para a identificação dos picos; depois

todos os valores observados são associados ao pico mais próximo, o que faz com que as divisões entre as classes tenham uma tendência a cair no ponto médio entre os picos. A entrada deste módulo permite somente dados de três bandas em composição falsa-cor [14].

No módulo ISOCLUST, que é baseado nos mesmos conceitos das rotinas do ISODATA, proposto por Ball e Hall, em 1985 [64], e dos métodos *H-means* e *K-means*, onde o usuário especifica o número de classes, o número de bandas que deseja e quantas iterações desejadas (este método fará uma análise das assinaturas dos *pixels* de todas as bandas indicadas)[13], apesar de, obrigatoriamente, gerar sementes, para a segmentação, sobre uma fusão de três bandas indicadas pelo usuário.

3.3.2 ENVI

A classificação não supervisionada é aplicada a um bloco (*cluster*) de *pixels* do conjunto de dados a imagem de um único arquivo-imagem, baseada somente na estatística destes dados, sem qualquer intervenção ou definição prévia do usuário das classes em treinamento.

São possíveis duas técnicas:

- a ISODATA, que calcula a média das classes igualmente distribuídas no espaço dos dados, e, iterativamente agrupa os *pixels* através da técnica da distância mínima. A cada iteração é recalculada a média, havendo, então, a reclassificação dos *pixels* de acordo com esta nova média. Logo, divisões, fusões e extinções de classes são realizadas com base nos parâmetros de limiar (*threshold*) de entrada. Todos os *pixels* são classificados na classe mais próxima, a menos que o desvio padrão ou a distância de limiar seja especificada, o que poderá acarretar a não classificação de alguns *pixels*, pois nem todos se encontrarão dentro deste critério de seleção. Sendo assim, este processo continua até que consiga um número de *pixels* de cada classe igual ou menor que o limiar de alteração de *pixel* escolhido (ou selecionado), ou até que o número máximo de iterações seja alcançado [66].
- a K-MEANS, que realiza uma análise dos agrupamentos existentes na imagem, com base na indicação do usuário sobre o número máximo de agrupamentos desejados, alocando, arbitrariamente,

seus centros pela imagem, e depois, iterativamente, reposicionando-os até que seja encontrada a divisão ótima das radiâncias dos *pixels*.

Em verdade, o ISODATA e o K-MEANS possuem os mesmos algoritmos-base, diferindo somente em alguns parâmetros a mais para o ISODATA [64].

3.4 TÉCNICAS DE CLASSIFICAÇÃO SUPERVISIONADA DOS PROGRAMAS

3.4.1 IDRISI

Dentre os classificadores supervisionados do IDRISI existem o PIPED, o MINDIST, o MAXLIKE e o FISHER. Desses, o mais utilizado, e o que gera os melhores resultados é o MAXLIKE.

O MAXLIKE é o classificador de máxima verossimilhança, onde a distribuição dos valores de reflectância em uma área de treinamento é descrita por uma função de densidade de probabilidade, desenvolvida com base na estatística Bayesiana. Assim, ele avalia a probabilidade de um determinado *pixel* pertencer a uma categoria e classifica o *pixel* para aquela com a qual ele tem a maior probabilidade de associação [14].

3.4.2 ENVI

Consiste na aplicação de um algoritmo de classificação onde todos os pixels são classificados conforme o método estatístico escolhido, neste programa: Método do Paralelepípedo, da Mínima Distância, do Mapeador de ângulo espectral e da Máxima Verossimilhança (Maxver). Será utilizado o último, pois é o que gera os melhores resultados, é a mais aplicada no tratamento de dados adquiridos por satélites e permite comparação com o do programa IDRISI.

O Maxver é baseado no princípio de que a classificação errada de um *pixel* particular não tem mais significado do que a classificação errada de qualquer outro *pixel* na imagem. O usuário determina a significância nos erros de atributos especificados para uma classe em comparação a outras. Cada amostra de treinamento é representada por *pixels* com reflexão característica e vale como área de referência dos níveis de quantização da classe. O resultado do Maxver é melhor quanto maior o número de *pixels* numa amostra de treinamento para implementá-los na matriz de covariância. [11] considera que “o método Maxver deve ser aplicado quando o analista conhece bem a imagem a ser classificada, para que possa definir classes que sejam representativas”.

4 BASE DE DADOS

Idealmente, como condições básicas e mínimas, para obtenção de uma verificação satisfatória da metodologia, foram estabelecidos os seguintes critérios (baseados no LANDSAT):

1) utilização de, no mínimo, quatro conjuntos de cenas – que possuam as classes em estudo, com cada cena para cada uma das estações do ano – para três áreas de fisiografias distintas, sendo que cada conjunto de cenas deverá observar, pelo menos, duas épocas diferentes;

2) cada cena deverá conter, pelo menos, registros de seis bandas: as três do espectro visível: azul, verde e vermelha; a infravermelha próxima e as duas infravermelhas médias (ver tabela 1);

3) as áreas das cenas deverão ser plenamente conhecidas, com a verdade terrestre já previamente levantada; e

4) disponibilidade do conhecimento de estudos das feições geográficas das áreas-teste, a fim de dirimir dúvidas que, certamente, irão surgir quando da classificação realizada pela metodologia.

Lastimavelmente, só houve o atendimento dos itens 2, 3 e 4 acima expostos, pois não foi possível obtenção nem disponibilização de áreas-teste por parte de Institutos de Pesquisa, nem de Universidades ou pesquisadores, nem por particulares.

Assim sendo, para estudos de comportamento espectral de alvos foi utilizada a cena (grade) 217/076 obtida pelo satélite LANDSAT-7 em abril de 2001, cedida pelo Professor Gilberto Pessanha Ribeiro.

4.1 PROGRAMA LANDSAT

O programa LANDSAT (abreviação de *Land Satellite*) é um dos mais antigos dentre os orbitais ainda em atividade e em franco desenvolvimento. É um dos poucos que podem ser considerados como um sucesso, pois os sensores do LANDSAT 5 continuam em funcionamento mesmo após 5 anos do prazo previsto de término das suas atividades.

A missão do programa LANDSAT é a de prover aquisições repetitivas de dados multiespectrais de média resolução da superfície da Terra, para que se possa realizar uma análise integrada dos mais variados temas. Atualmente este é o único sistema capaz de prover a comparação dos dados atuais de uma determinada área

com dados antigos, pois este sistema existe desde 1972. Assim, o programa LANDSAT possui o mais longo registro histórico da superfície terrestre [45].

A sua última missão, a sétima (daí chamar-se o satélite de LANDSAT-7), foi lançada em 1999, sendo sua realização um convênio entre a NASA (*National Administration Space Agency*), a NOAA (*National Oceanic and Atmospheric Administration*) e o USGS. Até o presente momento, a missão 5 está em operação e a 7 apresenta problemas técnicos no sensor SLC, desde 31 de maio de 2003: ainda procura-se uma correção deste, via *software*. Uma alternativa que está sendo proposta é a utilização do produto denominado LANDSAT 7 Composto [16].

A informação já disponibilizada por esta série permite uma enorme gama de estudos, devido tanto a diversidade dos sensores utilizados nas versões, quanto na variabilidade dos dados disponíveis que proporcionam a realização de séries temporais de cerca de 10 anos (LANDSAT 5 e LANDSAT-7).

Para melhor compreensão do comportamento espectral dos alvos obtidos por esta missão, são mostradas a seguir as respectivas faixas espectrais dos sensores já embarcados.

TABELA 1 – Satélites do programa LANDSAT e respectivos sensores embarcados

<u>SATÉLITE</u>	<u>SENSOR</u>	<u>BANDAS ESPECTRAIS</u> (μ)	<u>RESOLUÇÃO</u> (m)
LANDSAT 1 E 2	RBV	(1) 0,48 a 0,57	80
		(2) 0,58 a 0,68	80
		(3) 0,70 a 0,83	80
	MSS	(4) 0,5 a 0,6	79
		(5) 0,6 a 0,7	79
		(6) 0,7 a 0,8	79
		(7) 0,8 a 1,1	79
LANDSAT 3	RBV	(1) 0,505 a 0,75	30
	MSS	(4) 0,5 a 0,6	79
		(5) 0,6 a 0,7	79
		(6) 0,7 a 0,8	79
		(7) 0,8 a 1,1	79
		(8) 10,4 a 12,6	240

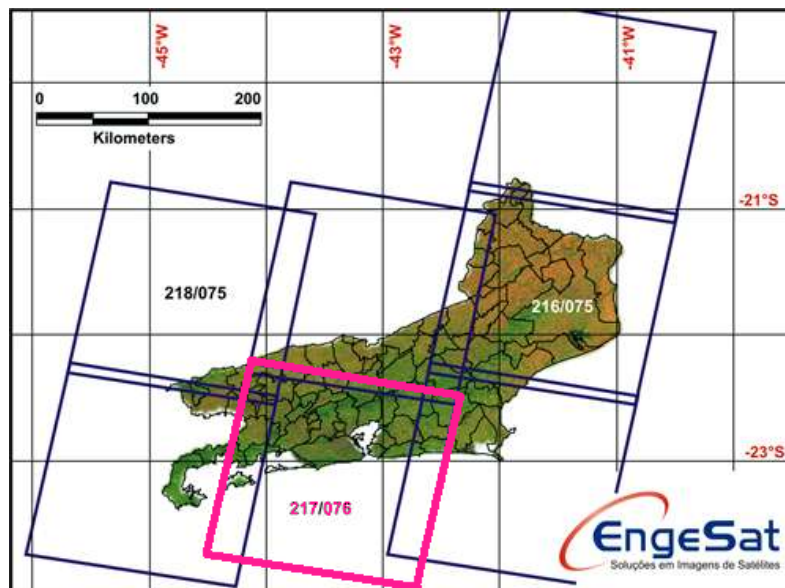
<u>SATÉLITE</u>	<u>SENSOR</u>	<u>BANDAS ESPECTRAIS</u> (μ)	<u>RESOLUÇÃO</u> (m)
LANDSAT 4 E 5	MSS	(4) 0,5 a 0,6	82
		(5) 0,6 a 0,7	82
		(6) 0,7 a 0,8	82
		(7) 0,8 a 1,1	82
		(1) 0,45 a 0,52	30
	TM	(2) 0,52 a 0,60	30
		(3) 0,63 a 0,69	30
		(4) 0,76 a 0,90	30
		(5) 1,55 a 1,75	30
		(6) 10,4 a 12,5	120
LANDSAT 7	ETM+	(7) 2,08 a 2,35	30
		PAN 0,50 a 0,90	15

Dentre as principais características do LANDSAT-7 destacam-se as seguintes [16], essenciais para a obtenção de um bom resultado da metodologia proposta:

- o período orbital é de, aproximadamente, 99 minutos, permitindo ao satélite dar 14 voltas ao redor da Terra por dia; a órbita é descendente, de norte para sul, com o satélite cruzando a linha do Equador entre 10:00 e 10:15 (hora local) em cada passagem; sendo assim, sincronizada com o Sol, isto é, sempre passa num mesmo local no mesmo horário solar;
- possuir compatibilidade de dados com as missões 4 e 5;
- possuir uma boa diversidade de bandas (oito, ao todo), o que permite uma análise integral válida das classes em estudo.
- predição de cobertura de nuvens a fim evitar a aquisição de uma cena ruidosa;
- garantia de precisão radiométrica absoluta de +/- 5%; e
- aperfeiçoamento da geometria da imagem, resultando numa maior precisão na correção de imagens apenas a partir de dados de efemérides geradas pelo GPS à bordo do satélite, sendo esta precisão muito próxima daquela obtida com imagens dotadas de referência cartográfica (com pontos de controle cartográficos).

4.2 CENA ANALISADA

Foi utilizada a cena (grade) 217/076 obtida pelo satélite LANDSAT-7 em abril de 2001 – com todas as suas oito bandas presentes e com cobertura de 5% (o Instituto de Pesquisas Espaciais – INPE classifica cada imagem pela percentagem de nuvens) na área continental – situada na região centro-sul do Estado do Rio de Janeiro.



Fonte: Engesat modificada.

FIGURA 1 – Grade de localização do LANDSAT 5 e 7 para o Estado do Rio de Janeiro (a cena utilizada está destacada na cor rosa).

A área da cena que será utilizada (somente a porção continental) encontra-se compreendida, aproximadamente, entre as coordenadas geográficas $43^{\circ} 30'$ a $45^{\circ} 30'$ de longitude oeste e $22^{\circ} 15'$ a $23^{\circ} 20'$ de latitude sul, abrangendo cerca de 17.000 Km².

O formato da imagem é o GeoTIFF (*Geographic Tagged Image File Format*), derivado do formato TIFF, que permite a associação de dados cartográficos aos *pixels* da imagem. Cada banda da cena possui profundidade, ou quantização de *pixel*, de 8 *bits*, admitindo, com isso, 256 níveis de radiância.

A cena possui nível de correção "1G", que é um nível de correção sistemática onde os valores da radiância são corrigidos e a geometria da cena ajustada – no caso daquelas distribuídas pelo INPE, por cartas na escala de 1 : 500.000. Teoricamente, a precisão geométrica e espacial de um produto 1G é de, pelo menos, 250 metros em áreas planas e ao nível do mar, pois os algoritmos de correção realizam uma modelagem da posição do satélite e da geometria do sensor, através de dados gravados pelo computador de bordo ao realizar a gravação das cenas (altitude, efemérides e parâmetros de atitude do satélite, dentre outros).

A projeção da cena é a UTM (*Universal Transverse Mercator*) e a reamostragem dos *pixels* foi realizada pelo método do vizinho mais próximo.



FIGURA 2 – Composição RGB 321 da cena utilizada.

4.3 DADOS E CARACTERIZAÇÃO DA CENA ANALISADA

A área da cena analisada compreende grande parte do Estado do Rio de Janeiro e uma diminuta parte do Estado de São Paulo. No Estado do Rio de Janeiro, são 31 municípios abarcados em sua totalidade (Rio de Janeiro, Niterói, São Gonçalo, Itaboraí, Maricá, Saquarema, Tanguá, Rio Bonito, Magé, Guapimirim, Duque de Caxias, Belford Roxo, Nova Iguaçu, Mesquita, São João de Meriti, Nilópolis, Japeri, Seropédica, Queimados, Miguel Pereira, Itaguaí, Mangaratiba, Rio Claro, Barra do Piraí, Pinheiral, Volta Redonda, Barra do Piraí, Mendes, Rio Claro, Eng. Paulo de Frontin e Paracambi), e 12 municípios abrangidos com cobertura parcial de seus territórios (Cachoeiras de Macacu, Paty do Alferes, Araruama, Silva Jardim, Petrópolis, Teresópolis, Paraíba do Sul, Angra dos Reis, Barra Mansa, Quatis, Valença e Vassouras).

A seguir será apresentado um resumo das características físicas da região da cena utilizada, baseada em [43], [52], [53] e [64], referentes ao Estado do Rio de Janeiro.

4.3.1 GEOMORFOLOGIA E RELEVO

Há duas unidades representativas de relevo neste Estado: a baixada, com terras de até 200m de altitude, e o planalto, com altitudes maiores de 200m.

A área de baixada é conhecida como Baixada Fluminense, a qual segue todo o litoral, ocupando, aproximadamente, metade da superfície do estado.

Na área perimetral da cidade do Rio de Janeiro erguem-se dois maciços: o da Tijuca e da Pedra Branca, com altitudes superiores a mil metros. Neste trecho, a baixada alarga-se, voltando a estreitar-se desde a região da baía de Guanabara até a região de Cabo Frio, onde ocorrem sucessivas pequenas elevações (altitudes entre 200 e 500m) chamadas de maciços litorâneos fluminenses.

Na cena utilizada, o litoral fluminense, que se localiza na área da Baixada, subdivide-se em duas regiões: a região de praias e cordões arenosos situada no extremo sul do Estado, estendendo-se de Parati até a Ilha de Itacuruçá; e a região de restingas, baixadas e lagunas, compreendida entre a Ilha de Itacuruçá e Arraial do Cabo.

A região de planalto situa-se no interior do Estado, possuindo como rebordo a Serra do Mar, a qual recebe diversas denominações: Serra dos Órgãos, Serra das Araras, Serra da Estrela e Serra do Rio Preto. A Serra da Mantiqueira localiza-se na parte noroeste do Estado, possuindo um decréscimo de altitude em direção ao interior, quando atinge 250m no Vale do Paraíba do Sul.

4.3.2 CLIMA

Na região de baixada predomina o clima tropical semi-úmido, onde as chuvas são abundantes, principalmente no verão e invernos secos. Temperaturas na média dos 24°C e chuvas com índice aproximado a 1.250mm/ano.

Junto à área limítrofe entre a Baixada e o planalto (região serrana) ocorre o clima tropical de altitude; os invernos são rigorosos e verões bastante quentes com temperaturas médias anuais de 16°C. As chuvas estão presentes de maneira abundante, em torno de 2.200mm/ano.

Com presença na maior parte do planalto, está o clima tropical de altitude, caracterizado por verões quentes e chuvosos, invernos frios e secos. A média da temperatura anual é de 20°C, e o índice pluviométrico atingido entre 1.500 a 2.000mm anuais.

4.3.3 HIDROGRAFIA

O rio principal do Estado é o Paraíba do Sul, que nasce em São Paulo e desemboca no Oceano Atlântico, cruzando todo o Estado do Rio de Janeiro. Seus principais afluentes são o Piabinha, o Piraí, o Paraibuna, o Pomba e o Muriaé.

Outros rios que se destacam na região são o Macabu, que deságua na Lagoa Feia, o Guandu e o Magé.

Muitas lagoas, formadas pelo fechamento de baías por cordões de areia, aparecem no litoral, sendo as que se destacam: a Lagoa Feia (a maior do Estado), a de Araruama, a de Maricá e a de Saquarema. Na capital do Estado encontram-se as de Jacarepaguá, de Marapendi e a Rodrigo de Freitas.

4.3.4 VEGETAÇÃO

A Mata Atlântica é um dos ecossistemas de floresta tropical mais ameaçados do mundo. Apesar de, originalmente, já ter ocupado mais de milhão de quilômetros quadrados – o equivalente a um terço da Amazônia – a Mata Atlântica está reduzida a apenas 7% de sua superfície original, em virtude de desordenada e gananciosa ocupação humana.

A região devastada da floresta foi totalmente fragmentada, com a predominância de aspectos antrópicos, representados pelas lavouras (comerciais e subsistência) e por pastos, em sua maioria plantados com gramíneas forrageiras (ou por vegetação secundária), em diversos estágios de sucessão, além da desenfreada ocupação urbana.

Destaca-se que nesta região encontram-se as duas maiores florestas urbanas do mundo: a do Maciço da Pedra Branca e a Floresta da Tijuca (esta cobre uma extensão de 3.300 hectares e foi reconhecida pela ONU como reserva da biosfera).

Atualmente, a vegetação remanescente recobre restritas porções, como, por exemplo, as encostas e os topos das serras, ocupadas ainda por florestas ombrófilas (Serra do Mar e da Mantiqueira), trechos do litoral – representados pelos manguezais, restinga, brejos e praias – campos de altitude, como o Maciço de Itatiaia, e campos da planície do delta do Paraíba do Sul.

4.4 DEFINIÇÃO DAS CLASSES EM ESTUDO

Em [3], há a definição de nove grandes classes, que se subdividem em vários níveis, a saber: Terra Urbana ou Construída, Terra Agrícola, Pastagem, Terra Florestal, Água, Terra Úmida, Terra Árida, Tundra e Neve ou Gelo Perene.

Quando da definição das classes que deveriam servir de teste da metodologia, foram consideradas aquelas com maior facilidade de percepção para a fotointérprete, sendo escolhidas, dentre as grandes classes, as de Terra Construída,

Terra Florestal e Água. Como se desejava uma quarta classe, foi escolhida a de Mangue, por ser interseção de duas classes (Água e Terra Úmida) e por representar um dos pontos críticos do Reconhecimento Automático de Padrões. A classe Outros representa aquelas outras diversas das classes em estudo.

Como cada uma das grandes classes engloba variados subníveis, adotou-se uma nomenclatura diferente, que será assim especificada:

- Área Construída: aquela indicativa do uso e da presença intensiva do homem, possuindo grande parte de sua superfície coberta por estruturas. Assim, nesta classe inclui-se metrópoles; cidades; vilas; quaisquer edificações e construções; áreas residenciais, comerciais, industriais e instituições, inclusive aquelas que possam estar situadas isoladamente das áreas urbanas.
- Água: engloba os cursos d'água, canais, rios, lagos, lagoas, represamentos artificiais, baías e estuários (penetrações ou braços de mar, que se estendem terra adentro).
- Área Florestal: aquela que apresenta uma densidade de cobertura das copas acima, e inclusive, de 10%, exercendo influência no clima e no regime hídrico. Esta área reúne áreas florestais decíduas (árvores que perdem suas folhas entre determinadas estações), "sempre-verde" (árvores que permanecem verdes durante o ano todo) e as mistas, que possuem árvores decíduas e "sempre-verde" em proporções acima de um terço; e
- Mangue: ocorre em presença de topografia plana na faixa costeira, sob influência constante do mar; por estar em ambiente de baixa energia, sendo composta por espécies vegetais halófitas, adaptadas a condições de intensa salinidade e de hidromorfismo. O solo é holomórfico, desenvolvido a partir de sedimentos marinhos e fluviais, com presença de matéria orgânica, apresentando, normalmente, predominância de argila e silte, elevadas quantidades de matéria orgânica e de sais solúveis em decorrência do contato com o mar. O ecossistema manguezal se caracteriza por ser excelente indicador de alterações no

nível do mar, uma vez que a vegetação apresenta marcante zonação estrutural, na faixa de transição entre o oceano e o continente, influenciada pelos diferentes graus de influência de penetração da água, e pelos processos geomorfológicos [57].

Ressalta-se que, quando da ocorrência mista em um determinado *pixel*, a quantização retratará a radiância média. O nome das classes indica qual a predominância do objeto ou objetos nela contidos.

Segundo [3], a Tabela 4 – Código de Cores de Uso da Terra ao Nível I, do USGS, a classe água será definida pela cor azul, a classe área construída pela cor vermelho e a classe área florestal pela cor verde. Para contraste com as outras cores, escolheu-se a amarela para representação da classe Mangue. Esta nomenclatura não é seguida pelos sistemas analisados, adotando cada um deles sua própria convenção, sem que o usuário tenha possibilidades de alterá-las.

4.5 CORREÇÃO DAS DISTORÇÕES GEOMÉTRICAS E RADIOMÉTRICAS

Como a cena já possuía um nível de correção 1G, o que indica tanto uma geometria quanto uma radiometria razoável, não houve necessidade de recorrer às técnicas de correção de distorções.

Apesar de não ter sido necessária a imposição das correções atmosférica e radiométrica (elas, em si, já significam a realização de outras pesquisas e trabalhos), indica-se, de acordo com a pesquisa realizada:

- para a correção radiométrica o modelo 6S [69], para a correção atmosférica o sistema SCORADIS [72], e as metodologias propostas em [23], [32] e [51]; e
- para as correções geométricas os procedimentos calcados em procedimentos fotogramétricos como o mapeamento direto e inverso e a reamostragem, dentre outros ([12], [37] e [67]).

4.6 COMPORTAMENTO ESPECTRAL DE ALVOS

O comportamento espectral de um objeto é variável devido a [41]:

- fatores ambientais: temperatura, umidade, chuva, neve, vento, luz solar, estação do ano, dentre outros;
- fatores físicos intrínsecos: das próprias estruturas dos objetos como composição, oxidação e envelhecimento;
- fatores físicos extrínsecos: insolação, estresse, fadiga, cisalhamento, inundação, terremotos, furacões; e
- fatores antrópicos: alterações provocadas pelo homem.

Portanto, o comportamento espectral de um objeto é mutável apesar da sua ínfima, ou nenhuma, variação intrínseca. Assim sendo, sistemas ou algoritmos baseados, unicamente, no comportamento espectral calcado em curvas de reflectâncias médias, são, sem sombra de dúvida, limitados e tendentes ao erro constante. O que se afigura como desejável é um sistema classificador que trabalhe diretamente com os registros espectrais, ao mesmo tempo em que permita agregação contínua de conhecimento acerca das variâncias espectrais admissíveis, provocadas pelos fatores ambientais.

Um objeto geográfico só poderá ser plenamente caracterizado e classificado com razoável nível de incerteza – i.e. reconhecido por suas propriedades - quando da modelagem matemática completa das suas quantizações espectrais nas diversas bandas de resolução radiométrica no espaço amostral ao qual pertence; o que envolve tempo e recursos, além do concurso de extensas pesquisas.

As diferenças espectrais entre imagens temporais de um mesmo objeto são resultantes da composição dos seguintes fatores:

- condições atmosféricas;
- estações do ano (sazonais);
- conteúdo de água do solo;
- cobertura vegetal;
- condições meteorológicas;
- fatores antrópicos;
- erros intrínsecos dos sensores;
- procedimentos de calibração dos sensores; e
- condições de transmissão dos dados (erros).

O que normalmente ocorre, com os atuais sistemas classificadores comerciais, é que os algoritmos de classificação são aplicados a um único arquivo-imagem, o que os limita à análise de uma banda isolada ou à fusão, ou composição ou, ainda, juntada, de 3 bandas quaisquer em falsa-cor.

Durante esta dissertação, quando for mencionada a composição entre três bandas espectrais, significará sempre que esta foi realizada segundo a composição RGB (*Red – Green – Blue*), isto é, a primeira banda será adicionada à cor vermelha (*RED*), a segunda sofre adição da cor verde (*GREEN*) e a terceira banda é adicionada à cor azul (*BLUE*).

A maioria das pesquisas e trabalhos realizados contemplam, somente, a utilização das bandas 3, 4 e 5, uma vez que tal composição é considerada como aquela capaz de detectar o maior número de classes.

Deste modo, para teste da metodologia proposta serão utilizadas as composições 543 e 453 na análise das classificações dos programas comerciais.

4.7 RECURSOS UTILIZADOS

Foi utilizado o programa IDRISI32 para recorte da cena 217/076, com todas as bandas, em duas áreas para teste da metodologia.

O programa MATLAB foi utilizado para implementar a arquitetura de lógica nebulosa da metodologia.

4.8 IMAGENS PARA TESTE DE PARTE DA METODOLOGIA PROPOSTA

Como a classe mangue não era a das que mais apareciam na cena utilizada, foi sugerido pela fotointérprete o recorte das seguintes áreas:




FIGURA 3– Recorte 1 - Marambaia (composição 453).

Nesta composição o mangue é mostrado na cor marrom – na sua maior porção - indicando uma reflectância menor na banda 4, em comparação com a água do oceano. Na cor laranja, bem forte, encontram-se as florestas, e os tons azulados indicam áreas urbanas.



FIGURA 4 – Recorte 2 - Pedra de Guaratiba (composição 543).

Na imagem acima a classe mangue aparece em tons mais escuros de verde; em tons de rosa aparecem as áreas construídas; em tons de verde claro aparecem as florestas e outras vegetações. O que se destaca nesta composição é a

cor azulada da água na embocadura do Rio Guandu e nos canais adjacentes – indicativo do carreamento de sedimentos e poluentes.

Estas imagens foram recortadas, como já dito, em todas as suas bandas, sendo utilizadas as bandas 1, 2, 3, 4, 5, e 7 para o teste da metodologia.

4.9 CLASSIFICAÇÕES DISPONIBILIZADAS PELA FOTOINTÉRPRETE

No transcurso desta dissertação o termo classificação visual indicará aquela que foi realizada pela fotointérprete - considerada, então como expressão da verdade terrestre - enquanto que a classificação digital será aquela realizada através do algoritmo implementado pela metodologia proposta.

As figuras 5 e 6 mostram a composição falsa-cor 321, que melhor se aproxima da cor verdadeira, para cada um dos recortes.



FIGURA 5 – Composição falsa-cor 321 recorte Marambaia.



FIGURA 6 – Composição falsa-cor 321 recorte Pedra de Guaratiba.

A seguir, são apresentadas as classificações visuais realizadas, segundo o exposto no item 4.4. Desta forma, a cor vermelha representa a classe Área Construída; a cor verde, a classe Área Florestal; a cor azul, a classe Água; a cor amarela, a classe Mangue e a cor preta, a classe Outros.




FIGURA 7 – Classificação visual do recorte Marambaia.




FIGURA 8 – Classificação visual do recorte Pedra de Guaratiba.

O que causou espécie durante estas interpretações foi que a fotointérprete utilizou-se, na maioria do tempo, das bandas isoladas, fazendo muito pouco uso das composições – o que fortalece a abordagem fundamental da metodologia proposta.

4.10 ANÁLISE DAS CLASSIFICAÇÕES REALIZADAS PELOS PROGRAMAS ANALISADOS

Embora incursionando no terreno indesejável da repetição cumpre salientar que esta análise foi realizada com a finalidade de verificar o resultado das técnicas utilizadas pelos programas já citados frente às quantizações de *pixel*, não envolvendo, por via de consequência, quaisquer considerações quanto às resoluções cartográfica e espacial.

Foi imposta uma limitação à quantidade de classes procuradas, já que o objetivo foi o da avaliação da classificação automática segundo as quatro classes já citadas anteriormente. Assim, foram escolhidas classificações com cinco classes, onde a quinta classe englobou, de acordo com as premissas básicas adotadas na presente investigação, os *pixels* não pertencentes às classes desejadas (classe Outros).

Por decorrência de não ter havido diferença, estatisticamente significativa, entre as classificações obtidas com as composições 453, e as demais combinações possíveis, serão mostradas, somente, as classificações obtidas com essa composição.

A diferença entre os classificadores supervisionados e os não supervisionados é a introdução de agrupamentos de pixels (amostras) nos

supervisionados. Assim, ao invés de serem feitas inferências estatísticas “*pixel a pixel*”, como nos não supervisionados, são realizadas inferências estatísticas nos agrupamentos de *pixels* indicados. Por isso é que a classificação não supervisionada mais se aproxima daquela preconizada pela metodologia proposta.

A classificação supervisionada apresenta mais um novo problema ao classificar todos os *pixels* existentes na imagem dentro das classes que foram indicadas. Logo, faz-se necessária a inserção da classe Outros no conjunto de amostras como uma nova classe que se deseja analisar.

Outra desvantagem da classificação supervisionada é que ela retira os conjuntos de treinamento da própria imagem, gerando a necessidade da ajuda de um fotointérprete que indique quais os locais dos conjuntos de treinamento, que, em verdade, realize uma fotointerpretação.

Para suporte no uso do programa IDRISI, foram utilizados os textos de ajuda integrados no próprio programa, bem como as apostilas [13], [14] e [71].

Para suporte no uso do programa ENVI, foram utilizados os textos de ajuda integrados no próprio programa, bem como as apostilas [54] e [34].

4.10.1 CLASSIFICAÇÃO NÃO SUPERVISIONADA NO IDRISI

4.10.1.1 CLUSTER

Para se utilizar este algoritmo é necessária a entrada de uma imagem que seja a composição falsa-cor de três bandas da cena, a escolha do nível de generalização (fino ou largo) e a escolha da regra de “clusterização” (agrupamentos de *pixels*). Depois de variados testes, verificou-se que o nível de generalização fino e a regra de “clusterização” de abandono dos grupos de *pixels* menos significantes obtiveram os melhores resultados.

Os resultados obtidos são mostrados a seguir.




FIGURA 9 – Classificação IDRISI-CLUSTER, ajuste fino, composição 453, para o recorte Marambaia.

Nota-se que a classe Água foi satisfatoriamente classificada na cor verde. Se levarmos em consideração que a classe Mangue está na cor amarela, vê-se que ela foi aparecer no Maciço da Pedra Branca. A classe Área Florestal, indicada na cor vermelha, apresentou ocorrência muito inferior à verdadeira. Fica muito difícil discernir entre os dois tons de azul apostos pelo módulo, qual seria a classe Área Construída e qual a classe Outros.

Quanto ao recorte Pedra de Guaratiba, obteve-se:




FIGURA 10 – Classificação IDRISI-CLUSTER, ajuste fino, composição 453 para o recorte Pedra de Guaratiba.

Aqui, o algoritmo indicou razoavelmente bem a classe Água em verde. A classe Área Florestal ficou também razoavelmente representada na cor azul, e a classe Área Construída, em amarelo, apresenta aproximação ruidosa. Já as classes Mangue e Outros ficaram completamente irreconhecíveis.

4.10.1.2 ISOCLUST

Este módulo é o único, tanto no IDRISI quanto no ENVI, que admite o concurso da entrada de até sete bandas, se for o desejo do usuário, mas solicita a indicação da composição tricolor que servirá de semente para a classificação dos agrupamentos, bem como o número de iterações e o número de agrupamentos (classes) desejados. As iterações significam a aplicação do método de máxima verossimilhança aos agrupamentos.

Foram introduzidas seis bandas, a composição 453, cinco agrupamentos, ou classes, e 10 e 50 iterações.




FIGURA 11 – Classificação IDRISI-ISOCLUST, 10 iter., para o recorte Marambaia (semente 453).

A classificação da Água, em verde, ficou razoável, bem como a de Área Florestal em vermelho (apesar de não ser toda classificada). Já o Mangue extrapolou, mais uma vez, os limites reais. A Área Construída, em azul escuro, está com aproximação razoável. A classe Outros aparece em azul claro.




FIGURA 12 – Classificação IDRISI-ISOCCLUS, 50 iter., para o recorte Marambaia (453).

A classificação Água, em verde, ficou razoável. A classe Área Florestal, em vermelho, ficou um pouco menor que a anterior. A classe Mangue ficou irreconhecível. As classes Área Construída, em azul claro, e Outros, na cor azul escuro, apresentam desvios consideráveis.




FIGURA 13 – Classificação IDRISI-ISOCCLUS, 10 iter., para Pedra Guaratiba (453).

Nesta classificação a classe mangue ficou representada na cor vermelha, mas se misturou com a água poluída, fazendo com que a classe água, na cor verde, ficasse menos representada. A cor amarela parece a área construída e a azul escuro a classe Área Florestais. A classe outros ficou representada pela cor azul claro que pegou área de floresta.




FIGURA 14 – Classificação IDRISI-ISOClust, 50 iter., para o recorte Pedra de Guaratiba (semente 453).

Este resultado se assemelha àquele expresso pela FIGURA 13, com uma leve expansão da classe Mangue, na exata medida da diminuição da classe Água.

4.10.2 CLASSIFICAÇÃO SUPERVISIONADA NO IDRISI – MAXLIKE

Este classificador admite a entrada de até sete bandas, logo, foram utilizadas as seis bandas para cada recorte.

Foram realizados testes com uma, com três e com sete amostras para os conjuntos de treinamento. Note-se que estes foram retirados da própria imagem, com base na imagem classificada disponibilizada pela fotointérprete.




FIGURA 15 – Classificação MAXLIKE com uma amostra para o recorte Marambaia.




FIGURA 16 – Classificação MAXLIKE com três amostras para o recorte Marambaia.




FIGURA 17 – Classificação MAXLIKE com sete amostras para o recorte Marambaia.

Pode-se observar que a FIGURA 17 (com sete amostras) obteve o melhor resultado. Comparando-se, então, este com a classificação de referência – a interpretação visual realizada pela fotointérprete, obteve-se a TABELA 2 (as percentagens exprimem as amostras coincidentes com a interpretação visual, logo aquelas classificadas corretamente).

TABELA 2 – Resultados da classificação MAXLIKE, com 7 amostras, para o recorte Marambaia.

CLASSES	Nº de amostras	Amostras corretamente classificadas
Água	200	98 %
Área construída	200	70 %
Área Florestal	200	70 %
Mangue	200	65 %
Todas classes	800	76 %
Sem contabilizar a classe Mangue	600	79 %

Como o recorte Marambaia, observou-se, visualmente, que a classificação com sete amostras obteve o melhor resultado para o recorte Pedra de Guaratiba. Comparando-se, então, este (FIGURA 18) com a classificação de referência – a interpretação visual realizada pela fotointérprete, obteve-se a TABELA 3.




FIGURA 18 – Classificação MAXLIKE com sete amostras para o recorte Pedra de Guaratiba.

TABELA 3 – Resultados da classificação MAXLIKE, com 7 amostras, para o recorte Pedra de Guaratiba.

CLASSES	Nº de amostras	Amostras corretamente classificadas
Água	200	80 %
Área construída	200	85 %
Área Florestal	200	80 %
Mangue	200	65 %
Todas classes	800	77 %
Sem contabilizar a classe Mangue	600	82 %

4.10.3 CLASSIFICAÇÃO NÃO SUPERVISIONADA NO ENVI

4.10.3.1 ISODATA

Apesar do ISODATA ser apresentado como uma classificação não supervisionada, ele permite, opcionalmente, a entrada de oito parâmetros, além daquele relativo ao número de classes, mas trabalha com apenas um arquivo-imagem, composto por uma única ou por uma composição falsa-cor de bandas. Logo, este não apresenta uma classificação não supervisionada clássica, disponibilizando parâmetros de entrada que irá causar confusão nos usuários pouco experientes. A utilização dos valores pré-definidos para cada parâmetro faz com que, usualmente, as convergências não se verifiquem.

O número de iterações significa o número de repetições do processo (neste caso, do ISODATA). A cada iteração, recalculam-se e reclassificam-se os *pixels*, considerando-se os novos valores médios. Além disso, o usuário pode determinar o desvio padrão e o erro de distância mínima. A classificação estará pronta quando o número de iterações definido pelo usuário for concluído, ou quando for alcançado o critério de número de pixels que mudam de classe (*Change Threshold* - CH) [34].

Estabeleceu-se, então, para as cinco classes desejadas (que, coincidentemente, é o mesmo valor padrão de classes do programa), 10 iterações para um CH de 5, e 50 iterações para um CH de zero. O desvio padrão e o erro de distância mínima não tiveram seus valores padrões (respectivamente, 1.000 e 5.000) alterados. Serão mostradas somente as classificações com 50 iterações, pois estas diferiram bem pouco das realizadas com 10 iterações.




FIGURA 19 – Classificação ENVI-ISODATA, 50 iter. CH zero, para o recorte Pedra de Guaratiba (composição 453).

Os resultados foram sofríveis. A classe Água aparece representada em vermelho, tendo perdido a área estuarina do Rio Guandu, classificada como Mangue. A classe Área Florestal, em amarelo, apresenta equívocos absurdos. Pior resultado, ainda, foi o obtido para a classe Mangue, na cor verde, onde foi considerada somente parte do estuário do Guandú. A área construída, em azul claro, foi satisfatoriamente classificada. Resta a representação em azul escuro para a classe Outros, que ficou bastante indefinida.




FIGURA 20 – Classificação ENVI-ISODATA, 50 iter. CH zero, para o recorte Marambaia (composição 453).

A classe Água, na cor vermelha, foi bem definida. A cor azul escuro representa a classe Área Florestal, que ficou aquém da média. A classe Mangue, em verde, abarcou áreas de outras classes, ao mesmo tempo em que omitiu as pequenas ocorrências dela própria. A classe Área Construída foi representada pela cor azul claro, apresentado um razoável desempenho, e a classe Outros, na cor amarela, apresentou resultado sofrível.

4.10.3.2 K-MEANS

Na utilização deste módulo, que mantém os mesmos parâmetros opcionais do módulo anterior, foram mantidos os parâmetros pré-definidos, alterando-se as classes desejadas para cinco e variando as iterações entre 10, 50 e 100, com CH, respectivamente, de cinco, zero e zero. Serão mostradas somente as classificações

com 50 iterações, pois estas não apresentaram variações estatisticamente significativas em relação às iterações de 10 e 100.




FIGURA 21 – Classificação ENVI-K_MEANS, 50 iter. CH zero, para o recorte Pedra de Guaratiba (composição 453).




FIGURA 22 – Classificação ENVI-K_MEANS, 50 iter. zero para o recorte Marambaia (composição 453).

Estas classificações obtiveram resultados bem assemelhados aos obtidos pelo método ISODATA, como esperado (item 3.3.2).

4.10.4 CLASSIFICAÇÃO SUPERVISIONADA NO ENVI – MAXVER

Este método só permite a entrada de uma composição, logo foi utilizada a 453.

Foram realizados testes com uma, com três e com sete amostras para os conjuntos de treinamento. Note-se que estes foram retirados da própria imagem, com base na imagem classificada disponibilizada pela fotointérprete.




FIGURA 23 – Classificação MAXVER com uma amostra para o recorte Pedra de Guaratiba.




FIGURA 24 – Classificação MAXVER com três amostras para o recorte Pedra de Guaratiba.




FIGURA 25 – Classificação MAXVER com sete amostras para o recorte Pedra de Guaratiba.

TABELA 4 – Resultados da classificação MAXVER, com 7 amostras, para o recorte Pedra de Guaratiba.

CLASSES	Nº de amostras	Amostras corretamente classificadas
Água	200	80 %
Área construída	200	70 %
Área Florestal	200	75 %
Mangue	200	80 %
Todas classes	800	76 %
Sem contabilizar a classe Mangue	600	75 %

Como para o recorte Pedra de Guaratiba, observou-se, visualmente, que a classificação com sete amostras obteve o melhor resultado para o recorte Marambaia. Comparando-se, então, este (FIGURA 26) com a classificação de referência – a interpretação visual realizada pela fotointérprete, obteve-se a TABELA 5.




FIGURA 26 – Classificação MAXVER com sete amostras para o recorte Marambaia.

TABELA 5 – Resultados da classificação MAXVER, com 7 amostras, para o recorte Marambaia.

CLASSES	Nº de amostras	Amostras corretamente classificadas
Água	200	95 %
Área construída	200	80 %
Área Florestal	200	85 %
Mangue	200	80 %
Todas classes	800	87 %
Sem contabilizar a classe Mangue	600	75 %

5 METODOLOGIA

5.1 ANÁLISE ESPECTRAL

Em decorrência do já exposto no item 4 (Base de Dados), foi empregada, como base experimental da presente proposição metodológica, uma única cena do satélite LANDSAT7.

O conjunto proposto para o treinamento inicial consistiu na escolha de sete *pixels* – considerados como os mais inequívocos – não vizinhos, e, ao mesmo tempo, situados fora das áreas dos recortes que serviram aos testes de detecção, para cada classe objeto de estudo. A seguir foram consideradas as quantizações dos vizinhos, imediatamente adjacentes. Foram obtidos, desta forma, sete conjuntos, de nove *pixels* cada, para cada uma das quatro classes. Há que se notar, com isso, que foram considerados apenas 28 conjuntos de treinamento para a parametrização da análise nebulosa. Foram realizadas inferências estatísticas simples nestes *pixels*, como média, desvio padrão e desvio padrão/média.

Em [17], [28], [35], e [41] há maiores informações acerca de análise espectral de alvos.

101	200	78	90	10
13	71	71	75	34
29	73	68	69	33
3	70	71	72	67
250	255	180	46	99

FIGURA 27 – Exemplo de uma quantização dos vizinhos imediatamente adjacentes.

A FIGURA 28 mostra os locais de onde foram retirados os *pixels* formadores dos conjuntos de treinamento.




FIGURA 28 – Visualização aproximada dos conjuntos de treinamento (pontos em vermelho), que se encontram fora das áreas dos recortes (retângulos brancos).

A TABELA 6 mostra, como exemplo, um conjunto de amostra para cada uma das classes em estudo nesta metodologia.

TABELA 6 – Exemplo do conjunto de treinamento.

ANÁLISE DOS VALORES ESPECTRAIS DAS CLASSES EM ESTUDO DA CENA 017/076 DO LANDSAT											
CLASSES	Imagem	Pixel	Coluna	Linha	Local	b1	b2	b3	b4	b5	b7
Água	Corte Baía de Guamabara	p1	940	1398	Entrada da Baía de Guanabara	71	41	31	11	12	12
		p2	941	1398		71	43	30	11	13	11
		p3	942	1398		72	43	31	12	14	11
		p4	940	1399		72	41	30	11	12	12
		p5	941	1399		69	41	31	12	12	11
		p6	942	1399		69	43	31	12	14	13
		p7	940	1400		70	42	31	12	12	12
		p8	941	1400		71	42	30	11	12	11
		p9	942	1400		72	42	29	11	13	13
					Desvio padr	1,20185	0,866025	0,726483	0,527046	0,866025	0,833333
					Média	71	42	30	11	13	12
					Desv/Média	0,016981	0,02062	0,023863	0,046053	0,06837	0,070755
Floresta	Corte Baía de Guamabara	p1	465	1360	Floresta da Tijuca - Alto da Boa Vista	66	44	30	69	55	25
		p2	466	1360		66	47	31	81	59	26
		p3	467	1360		64	47	30	82	56	25
		p4	465	1361		65	46	32	78	58	24
		p5	466	1361		64	46	32	88	62	26
		p6	467	1361		63	47	31	87	65	26
		p7	465	1362		65	46	31	79	58	25
		p8	466	1362		65	45	33	86	62	27
		p9	467	1362		66	48	34	91	66	29
					Desvio padr	1,054093	1,20185	1,333333	6,63325	3,855011	1,452966
					Média	65	46	32	82	60	26
					Desv/Média	0,016245	0,026002	0,042254	0,080566	0,064131	0,056123
Área Construída	Corte Baía de Guamabara	p1	976	1155	Área urbana perto da praia de Icarai	102	77	75	38	75	69
		p2	977	1155		107	85	95	49	92	81
		p3	978	1155		94	73	79	47	87	83
		p4	976	1156		97	74	72	36	59	50
		p5	977	1156		85	58	58	30	74	69
		p6	978	1156		98	71	72	41	89	79
		p7	976	1157		96	70	70	39	72	64
		p8	977	1157		91	66	64	34	51	42
		p9	978	1157		93	68	71	38	69	62
					Desvio padr	6,333333	7,483315	10,27673	5,967505	13,70016	13,92041
					Média	96	71	73	39	74	67
					Desv/Média	0,066049	0,104906	0,140992	0,152578	0,184583	0,209155
Mangue	Cena	p1	98	469	Tese final corte restinga	68	47	33	78	45	18
		p2	99	469		70	47	33	76	45	20
		p3	100	469		72	47	33	77	44	20
		p4	98	470		68	48	33	75	46	19
		p5	99	470		68	47	34	76	47	20
		p6	100	470		68	47	33	78	46	20
		p7	98	471		69	46	32	73	45	20
		p8	99	471		67	48	33	77	45	19
		p9	100	471		69	48	33	76	45	17
					Desvio padr	1,481366	0,666667	0,5	1,563472	0,866025	1,092906
					Média	69	47	33	76	45	19
					Desv/Média	0,021538	0,014118	0,015152	0,020512	0,019104	0,056856

5.2 BREVE INTRODUÇÃO A LÓGICA NEBULOSA

O filósofo grego Aristóteles, fundador da ciência da Lógica, estabeleceu um conjunto de regras rígidas de forma que conclusões pudessem ser aceitas como válidas. Logo, a Lógica baseia-se em premissas e conclusões, o que leva a esta ser binária, isto é, uma declaração será falsa ou verdadeira, não existindo a parcialidade.

A Lógica Nebulosa ou Difusa (*Fuzzy*) foi desenvolvida por Lofti A. Zadeh, da Universidade da Califórnia, em Berkeley, na década de 60. Ela “viola” as suposições acerca do conceito de dualidade, estabelecendo que algo pode e deve coexistir com seu oposto, fazendo com que esta lógica pareça natural, até mesmo inevitável.

A maioria das experiências e ações humanas não podem ser classificadas como falsas ou verdadeiras, nem como branco ou preto, simplesmente. Um exemplo clássico é: um copo foi preenchido com água até sua metade. Ele está cheio ou vazio? Obviamente que nenhuma dessas duas alternativas cabem como resposta. Então, ele está parcialmente cheio, ou seria parcialmente vazio? Em verdade, entre a certeza de ser e a certeza de não ser existem variados graus de incerteza. Assim, a LN, com base na teoria dos conjuntos nebulosos, tem se mostrado mais adequada para o tratamento das incertezas, que permeiam o mundo real, o natural.

Maiores detalhes poderão serem vistos em [62], [4], [48],

5.3 METODOLOGIA PROPOSTA

A metodologia aqui proposta pode ser resumida, esquematicamente, pela FIGURA 29.

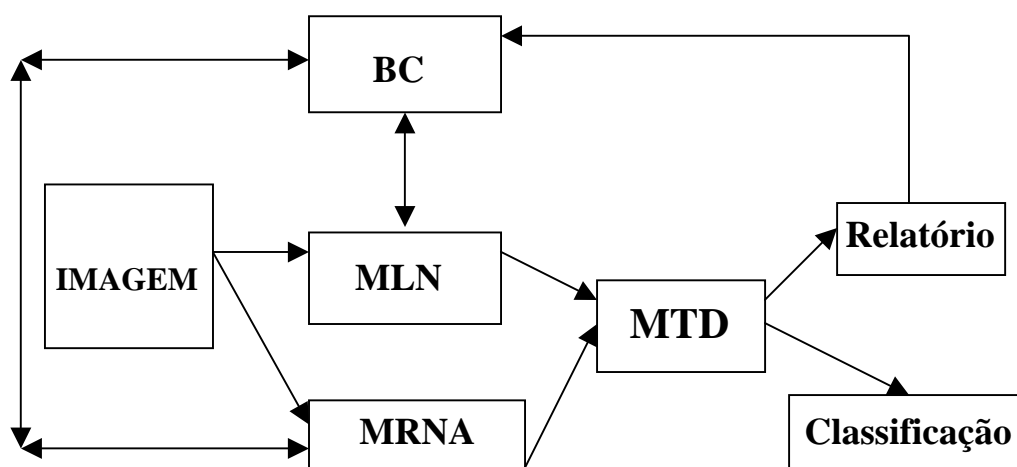


FIGURA 29 – Estrutura proposta para um classificador automático.

Está previsto o estabelecimento de um Banco de Classes (BC) implementado, primeiramente, com parâmetros definidores, para cada banda, dos valores e correlações espectrais das classes que se deseja analisar. O limite do número de classes será determinado pelo usuário (quantas ele assim o desejar), sendo este limite correspondente ao número dos conjuntos de quantizações implementados por banda. Este BC se comunicará tanto com o módulo Rede Neural Artificial (MRNA), quanto com o módulo Lógica Nebulosa (MLN), trocando assinaturas espectrais entre os mesmos.

O BC, o MRNA e o MNL deverão ser implementados com as quantizações definidas por bandas e por classes, com o concurso dos conhecimentos de um ou mais fotointérpretes. Com base nestes dados, serão gerados conjuntos de treinamento e regras.

O resultado do cotejo das saídas de MLN e de MRNA será submetido ao módulo Tomador de Decisão (MTD). Se as diferenças forem, somente, de natureza quantitativa – decorrentes da variação de estação climática, calibração, variação do azimute do sol (no caso dos sensores passivos), por exemplo – o MTD reajustará os valores de quantização admitidos pelas classes existentes no BC, sem a criação de novas classes. Em havendo diferenças qualitativas – não correspondência absoluta com os níveis de quantização e correspondentes variâncias admitidas, já armazenados no BC, para cada banda espectral e para cada classe – o MTD emitirá relatório para que o usuário possa introduzir a nova classificação. É de se esperar que esta abordagem resulte em um sistema estável.

Para o treinamento do classificador, será necessária a utilização de, no mínimo, quatro conjuntos de cenas - para cada sensor orbital – que possuam as classes desejadas (cada cena para cada uma das estações do ano), sendo que cada conjunto deverá observar, pelo menos, duas épocas diferentes. Cada cena deverá conter todas as bandas.

Assim sendo, quando da entrada da primeira imagem, este classificador irá fazer suas inferências baseado somente no conhecimento implementado previamente no BC. Ao final, o fotointérprete irá corrigir as classificações realizadas (talvez com necessidade de ida a campo). Após sucessivas entradas, a imagem estará plenamente classificada, naquelas classes de interesse. Realiza-se, então o mesmo processo até que todas as imagens de treinamento sejam esgotadas. Com isto, o classificador irá acumular os conhecimentos adquiridos, fazendo com que ele se torne um “especialista” naquelas classes de interesse da organização usuária.

Posteriormente, ele deverá ser utilizado em outras cenas, que contenham as classes de interesse, o que ampliará, de forma cada vez mais econômica, o seu poder de análise e síntese. Ressalta-se que este classificador, por utilizar somente valor espectral isoladamente de cada um dos *pixels* de várias bandas, é, por conseguinte, do tipo multiespectral “*pixel a pixel*” [27].

Assim, a metodologia preconizada está inserta na técnica de classificação híbrida (item 2.2.3), no estágio inicial de sua implantação, tendendo, cada vez mais, com o aprendizado proporcionado pela frequência de utilização e pela expansão do BC, a se tornar inteiramente automática.

A consecução do presente trabalho esbarrou numa variada gama de contratempos, tais como:

- a) enorme tempo despendido na definição das cenas e dos sensores a serem utilizados;
- b) após a definição da indisponibilidade financeira para a aquisição do conjunto mínimo de cenas, os problemas havidos com os satélites LANDSAT7 e CBERS1, limitaram ainda mais as premissas fundamentais da investigação;
- c) conseguir o concurso de fotointérprete com reconhecida competência e que se dispusesse a tal trabalho sem a devida compensação financeira;
- d) conseguir, gratuitamente, ao menos uma cena de satélite imageador que abarcasse área do município do Rio de Janeiro – ou que a ele fosse contígua – de modo a diminuir os custos de ida ao campo;
- e) aguardar o esgotamento do longo prazo consumido pela fotointerpretação, uma vez que dependia do tempo vago e da disposição da fotointérprete; e
- f) a disponibilidade de apenas uma cena inviabilizou a implementação do MRNA e, por via de consequência, dos demais módulos previstos.

O sucesso da presente investigação ficou restrito ao desempenho do MLN, o qual, afortunadamente, apresentou resultados bem superiores àqueles apresentados pelos sistemas comerciais. Não foi sem intenção que os experimentos na MLN partiram de um número mínimo muito limitado de amostras.

5.4 DESENVOLVIMENTO DO MÓDULO LÓGICA NEBULOSA

O MLN protótipo tem por núcleo o módulo *Fuzzy* do programa MATLAB. Maiores detalhes técnicos acerca deste módulo poderão ser encontrados em [39].

A representação esquemática do MLN implementado está representada na FIGURA 30.

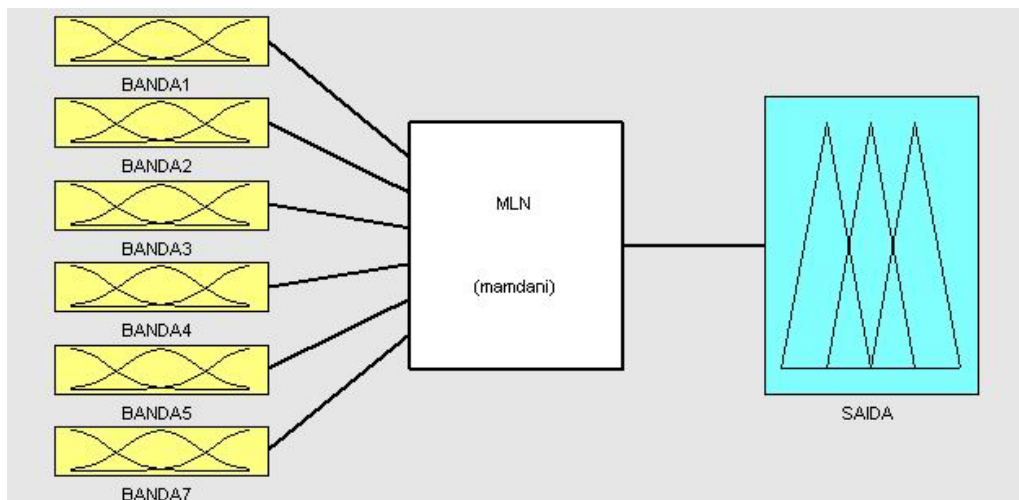


FIGURA 30 – Modelo implementado no módulo *Fuzzy* do MATLAB.

A entrada do MLN consiste de uma matriz com todos os valores dos pixels de cada uma das bandas utilizadas (seis no atual estudo). Logo, as seis imagens da cena foram transformadas em uma única matriz de entrada onde cada linha desta representa um *pixel* específico da cena, e cada coluna corresponde a cada uma das bandas utilizadas.

O método de inferência utilizado é o Mandani, com os métodos de “defuzzificação” do menor dos máximos, como pode ser melhor observado na FIGURA 31.

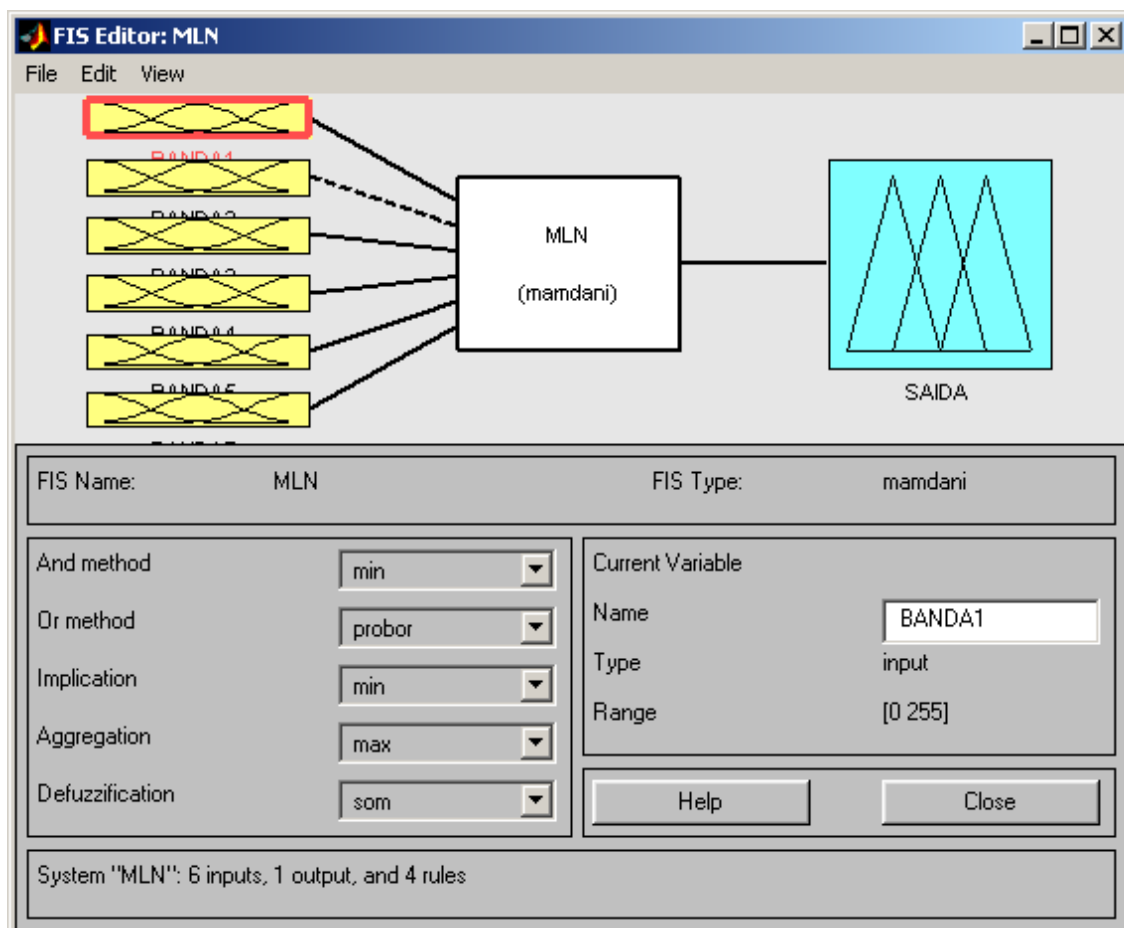


FIGURA 31 – Tela de entrada do módulo MLN implementado.

A “fuzzificação” das entradas foi implementada observando-se os conjuntos definidores das classes e os conjuntos de treinamento. Assim, cada classe foi representada por uma função de pertinência específica para cada banda, como, por exemplo, para a classe Mangue existem, então, seis funções de pertinências específicas para cada uma das bandas (Mangue1, Mangue2, Mangue3, Mangue4, Mangue5 e Mangue7), como pode ser melhor visualizado nas FIGURA 34, FIGURA 33 e FIGURA 34.






FIGURA 32 – Telas das funções de pertinência de entrada do MLN relativas as bandas 1, 2 e 3.






FIGURA 33 – Telas das funções de pertinência de entrada do MLN relativas as bandas 4, 5 e 7.




FIGURA 34 – Tela da função de saída do MLN implementado.

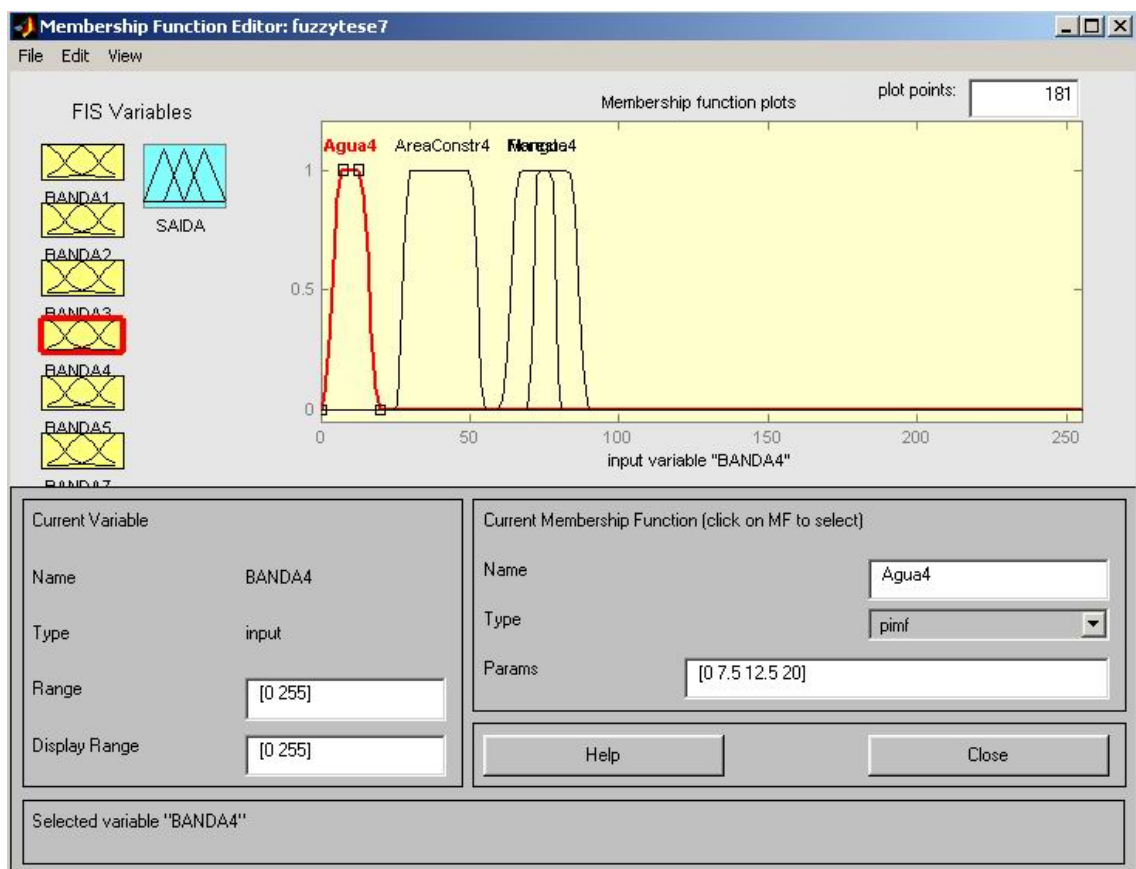


FIGURA 35 – Exemplo da tela das funções de pertinência de entrada para a banda 4, com detalhe para os parâmetros da função Agua4.

As regras foram implementadas observando-se o conhecimento adquirido com os estudos realizados com a fotointérprete.

O conjunto de regras otimizado que apresentou o melhor resultado, mas que não significa que não possa ser mais aprimorado, é o seguinte:

1. If (BANDA1 is Agua1) and (BANDA4 is Agua4) and (BANDA5 is Agua5) then (SAIDA is Agua);
2. If (BANDA1 is AreaConstr1) and (BANDA3 is AreaConstr3) and (BANDA7 is AreaConstr7) then (SAIDA is AreaContr);
3. If (BANDA1 is Floresta1) and (BANDA3 is Floresta3) and (BANDA4 is Floresta4) then (SAIDA is Floresta); e
4. If (BANDA3 is Mangue3) and (BANDA4 is Mangue4) and (BANDA5 is Mangue5) then (SAIDA is Mangue).

Quando não houver atendimento de nenhuma destas regras, a saída será a classe Outros.

Este conjunto se mostrou extremamente simples e rápido, pois um computador com processador de 1GHz e com 256MB de memória tipo DDR, levou, aproximadamente, três minutos para gerar a imagem de saída.

Tal imagem se apresenta em formato tipo BitMaP (BMP), pois não utiliza nenhum esquema de compressão de dados, com somente cinco quantizações de *pixel*, logo em tons de cinza, onde: zero significa a classe Água; 60 significando a classe Área Construída; 130 a classe Outros; 190 a classe Floresta e 255 significando a classe Mangue. Posteriormente, a imagem foi colorizada de acordo com o exposto no item 4.4.

6 RESULTADOS OBTIDOS

6.1 CLASSIFICAÇÕES OBTIDAS

As classificações obtidas pelo MLN para o recorte Marambaia e para o recorte Pedra de Guaratiba são mostradas nas figuras a seguir.




FIGURA 36 – Resultado da classificação digital (saída do MLN implementado) do recorte Marambaia.




FIGURA 37 – Resultado da classificação digital (saída do MLN implementado) do recorte Pedra de Guaratiba.

6.2 ANÁLISE QUALITATIVA DOS RESULTADOS

Em seqüência, serão mostradas as classificações, resultantes do algoritmo implementado, cotejadas com as realizadas pela fotointérprete.




FIGURA 38 – Classificação visual (a) e a classificação digital (b) do recorte Marambaia.

Visualmente, é possível verificar que a classe Mangue não foi plenamente reconhecida pela classificação digital, ficando misturada com a classe Área Florestal. As demais classes apresentaram razoável classificação.




FIGURA 39 – Classificação visual (a) e a digital (b) do recorte Pedra de Guaratiba.

No recorte Pedra de Guaratiba, a classificação digital apresentou um desempenho melhor do que no recorte anterior, em relação a classe Mangue. Esta e a classe Água obtiveram excelentes resultados quando se considera a presença de

sedimentos e poluentes presentes, que, em sua maioria, foi corretamente classificados na classe Outros (em preto).

Nas tabelas a seguir são apresentados os resultados obtidos na avaliação da classificação digital comparada com a classificação de referência – a interpretação visual realizada pela fotointérprete – para cada uma das imagens analisadas. A percentagens exprimem as amostras coincidentes com a interpretação visual realizada pelo fotointérprete, logo aquelas classificadas corretamente.

TABELA 7 – Resultados da classificação obtida para o recorte Marambaia.

CLASSES	Nº de amostras	Amostras corretamente classificadas
Água	200	96 %
Área construída	200	75 %
Área Florestal	200	85 %
Mangue	200	50 %
Todas classes	800	76 %
Sem contabilizar a classe Mangue	600	85 %

TABELA 8 – Resultados da classificação obtida para o recorte Pedra de Guaratiba.

CLASSES	Nº de amostras	Amostras corretamente classificadas
Água	200	90 %
Área construída	200	80 %
Área Florestal	200	75 %
Mangue	200	70 %
Todas classes	800	79 %
Sem contabilizar a classe Mangue	600	82 %

É relevante a obtenção de resultados mais próximos à verdade terrestre que aqueles obtidos pelos classificadores comerciais, mesmo com o concurso de um número muito limitado de amostras e sem qualquer treinamento e sem o Banco de Classes, superando, em muito, as expectativas consagradas para a interpretação assistida de áreas desconhecidas e para os programas comerciais de interpretação automática.

No que se refere à classificação assistida proporcionada pelo programa ENVI, módulo MAXVER – considerado por muitos profissionais da área de SR como o melhor existente – os resultados apresentados, exceção da classe Mangue, são, também significativos, conforme a TABELA 9.

TABELA 9 – Acertos obtidos pelo MLN e pelo ENVI (MAXVER).

CLASSES	Recorte Pedra de Guaratiba		Recorte Marambaia	
	MLN (%)	MAXVER (%)	MLN (%)	MAXVER (%)
Água	90	80	96	95
Área Construída	80	70	75	80
Área Florestal	75	75	85	85
Mangue	70	80	50	80
Todas as classes	79	76	76	87
Sem contabilizar a Mangue	82	75	85	85

Há que se notar que os resultados obtidos pelo MLN não derivaram de qualquer tratamento estatístico ou de rede de treinamento, o que autoriza expectativa promissora quanto à abordagem metodológica aqui proposta. O nível de acerto do MLN, consideradas todas as classes, foi de 79 % (recorte Pedra de Guaratiba) e 76% (recorte Marambaia), o que indica que uma melhora nas regras para a classe Mangue fará com que se ultrapasse, com relativa facilidade, os 80% de acerto.

É de se esperar, pelos resultados obtidos, que com treinamento adequado e implementação dos demais módulos, o classificador proposto supere, com folga, os 90% de acerto.

7 CONCLUSÕES

Apesar de ter sido implementado, apenas, um dos módulos da metodologia aqui proposta, esta se mostrou eficaz ao obter desempenho assemelhado ao que é considerado como o melhor programa comercial de classificação assistida, e batendo, inapelavelmente, os pacotes comerciais destinados às classificações automáticas.

Verificou-se, de imediato, o melhor desempenho introduzido pelo MLN, o qual poderá sofrer um salto mais positivo, quando do emprego de regras mais sofisticadas. Assim sendo, é admissível esperar um semelhante incremento – em qualidade – quando o MRNA estiver operando.

Desta forma, a viabilidade da metodologia aqui proposta está comprovada, no que tange à eficiência do MLN, e a implementação futura de todo o sistema classificador assume expectativa promissora.

7.1 RECOMENDAÇÕES

Os resultados obtidos com a metodologia proposta – intencionalmente mais extensível que, propriamente, multiplicável – seguem as seguintes recomendações:

- estudos futuros abarcando um número maior de sensores orbitais e aéreos, multi e hiperespectrais, com a organização espaço-temporal preconizada no item 4 – Base de Dados – manifestam-se como amplamente desejáveis;
- o aumento da resolução espectral da pesquisa, com o concurso do maior número de sensores multi e hiperespectrais, deverá ser objeto de consideração pelos centros de pesquisa e pelos governos;
- a incorporação futura, a esta metodologia, de técnicas de segmentação (crescimento de regiões, *fuzzy C-Means*, *multi-threshold*) – como as propostas e testadas por [10], [38], [56], [65] e [5] – como também as por textura – [31], [6] e [60] – , contribuirão para o aumento do poder resolutivo do classificador;
- a consideração de outras técnicas calcadas, fundamentalmente, em modelos de correlação entre quantizações dos *pixels*

nas diversas bandas espectrais, em diferentes épocas e condições ambientais, só irá agregar valor a uma metodologia voltada para o reconhecimento dos objetos geográficos, a partir das suas propriedades intrínsecas, possibilitando, assim, novas e mais eficientes arquiteturas para as bases de dados dos Sistemas de Informações Geográficas (SIG) – libertando-as das limitações decorrentes da semântica definida por atribuições, uma vez que as propriedades inerentes a cada classe de objeto estarão determinadas em níveis de incerteza cada vez menores.

8 REFERÊNCIAS BIBLIOGRÁFICAS

- [1] AGUIAR, H., JÚNIOR, O. Lógica Difusa: Aspectos Práticos e Aplicações. Rio de Janeiro: Editora Interciência LTDA, 1999.
- [2] ALVES, D. S., PEREIRA, J. L. G., DE SOUSA, C. L., SOARES, J. V., MOREIRA, J. C., ORTIZ, J. °, SHIMABUKURO, Y. E., YAMGUCHI, F. Análise comparativa de técnicas de classificação de imagens do sensor Landsat / TM para caracterização de áreas desflorestadas. Simpósio Brasileiro de Sensoriamento Remoto, Santos, 14-18 de setembro de 1998. [online] Disponível na Internet via WWW. URL: <http://iris.sid.inpe.br:1908/col/sid.inpe.br/banon/2001/03.14.09.08/doc/@index.html>. Arquivo capturado em 20 de dezembro de 2003.
- [3] ANDERSON, James R., HARDY, Ernest E., ROACH, John T. et al. Sistema de Classificação do Uso da Terra e do Revestimento do Solo para Utilização com Dados de Sensores Remotos. Rio de Janeiro: IBGE, 1979.
- [4] AZEVEDO, Fernando M., BRASIL, Lourdes M., OLIVEIRA, R. C. L. de. Redes Neurais com Aplicações em Controle e em Sistemas Especialistas. Florianópolis: Bookstore, 2000.
- [5] BHALERAO, A. Multiresolutin Image Segmentation. PhD Thesis, Department of Computer Science, University of Warwick, November 1991. [online] Disponível na Internet via WWW. URL: <http://www.dcs.warwick.ac.uk/people/academic/Abhir.Bhalerao/research/pubs.html>. Arquivo capturado em 04 de maio de 2004.
- [6] BHATTACHARYA, A. K., SRIVASTAVA, P. K., BHAGAT, A. A modified texture filtering technique for satellite images. *Proc. ACRS 2001 - 22nd Asian Conference on Remote Sensing*, Vol. 1, pp. 262-267. Singapore, 5-9 novembro de 2001. [online] Disponível na Internet via WWW. URL: <http://www.crisp.nus.edu.sg/~acrs2001/>. Arquivo capturado em 04 de maio de 2004.
- [7] CÂMARA, Gilberto, MEDEIROS, José Simeão de. Tendências de Evolução do Geoprocessamento. In: DELGADO ASSAD, Eduardo, SANO, Edson Eyji. *Sistema de Informações Geográficas: Aplicações na Agricultura*. 2. ed. Brasília: EMBRAPA, 1998. Cap. 20, p. 411-424.

- [8] CARPENTER, G. A., GOPAL, S., MACOMBER, S., MARTENS, S. *et al.* *A neural network method for efficient vegetation mapping.* *Remote Sensing of Environment*, vol. 70, no. 3, pp. 326-338, Dezembro de 1999.
- [9] CONWAY, Eric D., The Maryland Space Grant Consortium. *An Introduction to Satellite Image Interpretation.* USA: The John Hopkins University Press, 1997.
- [10] COUTINHO, Alexandre C. *Segmentação e classificação de imagens LANDSAT-TM para o mapeamento dos usos da terra na região de Campinas, SP.* Dissertação de Mestrado em Ecologia - Universidade de São Paulo, Instituto de Biociência, São Paulo, 1997. [online] Disponível na Internet via WWW. URL: <http://www.segmenta.cnpm.embrapa.br/>. Arquivo capturado em 02 de março de 2003.
- [11] CRÓSTA, Álvaro P. *Processamento Digital de Imagens de Sensoriamento Remoto.* ed. revisada. Campinas, SP: IG/UNICAMP, 1993.
- [12] DALGE, Julio Cesar Lima. *Correção Geométrica de Sensoriamento Remoto.* [online] Disponível na Internet via WWW. URL: <http://www.dpi.inpe.br/~julio/>. Arquivo capturado em 11 de agosto de 2003.
- [13] EASTMAN, J. R. *Guide to GIS and Image Processing – Volume 1.* Programa IDRISI32 release 2. versão 32.20. MA, USA: Clark Labs, 2001.
- [14] EASTMAN, J. R. *Manual do Usuário – Versão digital (Portable Document File) – Introdução e exercícios tutoriais. IDRISI for Windows versão 2.* Versão em português. Porto Alegre: Centro de Recursos IDRISI, Brasil, 1998. [online] Disponível na Internet via WWW. URL: <http://www.ecologia.ufrgs.br/labgeo/cridrisi/manual.htm>. Arquivo capturado em 01 de abril de 2001.
- [15] ELVIDGE, Christopher D., LUNETTA, Ross S. (editors). *Remote Sensing Change Detection – Environmental Monitoring Methods and Applications.* USA: Ann Arbor Press, 1998.
- [16] Ficha técnica resumida – LANDSAT 7 ETM +. ENGESAT – Imagens de Satélites. [online] Disponível na Internet via WWW. URL: <http://www.engesat.com.br/satelites/landsat7.htm>. Arquivo capturado em 21 de julho de 2004.

- [17] FLORENZANO, Teresa Gallotti. Imagens de Satélite para Estudos Ambientais. São Paulo: Oficina de Textos, 2002.
- [18] FONSECA, Leila Maria Garcia. Processamento Digital de Imagens. Apostila disponível em formato pdf. [online]. Disponível na Internet via WWW. URL: http://www.dpi.inpe.br/~leila/dip_material.html. Arquivo capturado em 20 de fevereiro de 2004.
- [19] FOODY, G.M. Fully Fuzzy Supervised Classification of Land Cover from Remotely Sensed Imagery with an Artificial Neural Network. *Neural Computing & Applications* vol.5, no. 4, pp. 238-247, 1997.
- [20] FOODY, G.M. Land Cover Classification by an Artificial Neural Network with Ancillary Information. *International Journal of Geographical Information Systems* vol.9, no. 5, pp. 527-542, 1995.
- [21] FU, LiMin. Neural Networks in Computer Intelligence. *Computer Science Series*. Singapore: McGraw-Hill International Editions, 1994
- [22] GONZALES, R. C., WOODS, R. E. Processamento de Imagens Digitais. São Paulo, Brasil: Editora Edgard Blücher LTDA, 2000.
- [23] HALL, F.G.; STREBEL, D.E.; NICKESON, J.E.; GOETZ, S.J. Radiometric rectification: toward a common radiometric response among multitemporal, multisensor images. *Remote Sensing of Environment*, v.35, p.11-27, 1991.
- [24] HAYKIN, Simon. Redes Neurais – Princípios e prática. 2ª edição. Porto Alegre: Bookman, 2001.
- [25] HOFMANN, T.; PUZICHA, J.; BUHMANN, M. Unsupervised segmentation on the basis of scale space features. Technical Report. Copenhagen: University of Copenhagen, 1996.
- [26] IBGE – Instituto Brasileiro de Geografia e Estatística. Introdução ao Processamento Digital de Imagens – Manuais Técnicos em Geociências – número 9. RJ, Brasil: 2001.
- [27] INPE – Instituto Nacional de Pesquisas Espaciais. Processamento Digital de Imagens - Uma introdução às técnicas de processamento digital de imagens de sensores remotos. [online] Disponível na Internet via WWW. URL: <http://www.dpi.inpe.br/cursos/pdi.htm>. Arquivo capturado em 29 de agosto de 2004.

- [28] INPE – Instituto Nacional de Pesquisas Espaciais. Projeto Educa SeRe III. [online] Disponível na Internet via WWW. URL: <http://www.inpe.br/unidades/cep/atividadescep/educasere/> Arquivo capturado em 14 de dezembro de 2000.
- [29] INPE – Instituto Nacional de Pesquisas Espaciais. SPRING – Sistema de Processamento de Informações Georeferenciadas. Disponível na Internet via WWW. URL: <http://www.dpi.inpe.br/spring/>. Arquivo capturado em 04 de maio de 2004.
- [30] KIL, D. H., SHIN, F. B. Pattern Recognition and Prediction with Applications to Signal Characterization. Woodbury, New York: AIP Press – American Institute of Physics, 1996.
- [31] KUMAR, V. V., RAO, A. N., DAMODARAM, A. A new unsupervised algorithm for texture segmentation. GISDevelopment.net, 2003 [online] Disponível na Internet via WWW. URL: <http://www.gisdevelopment.net/technology/ip/index.htm>. Arquivo capturado em 22 de julho de 2003.
- [32] KUNTSHIK, Geraldo, BITTENCOURT, Marisa D. Correção de imagens Landsat TM5 e avaliação do erro decorrente do uso de imagens NDVI não corrigidas. Anais X SBSR, Foz do Iguaçu, 21-26 abril de 2001, INPE, p. 1277-1284.
- [33] KURY, Eduardo B., VIEIRA, Carlos A. O. Classificação automática de imagens de alta resolução. I Workshop sobre Geoprocessamento da UFV – UFVGEO 2002. [online] Disponível na Internet via WWW. URL: <http://www.ufv.br/nugeo/ufvgeo2002/resumos/9-eduardo.pdf>. Arquivo capturado em 04 de março de 2004.
- [34] LANGENWALTER, Jürgen. Guia do ENVI. Research Systems Inc. – RSI. SulSoft. [online] Disponível na Internet via WWW. URL: <http://www.envi.com.br/guia/>. Arquivo capturado em 24 de agosto de 2004.
- [35] LILLESAND, Thomas M., KIEFER, Ralph W. Remote Sensing and Image Interpretation. Third edition. USA: John Wiley & Sons, 1994.
- [36] LOCH, Carlos. A Interpretação de Imagens Aéreas – Noções básicas e algumas aplicações nos campos profissionais. 4ª edição. Florianópolis: Editora da UFSC, 2201.

- [37] MACHADO E SILVA, A. J. F.; D'ALGE, J. C. L. Avaliação da qualidade geométrica das imagens TM-LANDSAT. Simpósio Latino-Americano de Sensoriamento Remoto, Gramado. Anais, p.73. INPE-8113-PRE/113, 1986. [online] Disponível na Internet via WWW. URL: <http://www.dpi.inpe.br/~julio/>. Arquivo capturado em 11 de agosto de 2003.
- [38] MANSOR, Shattri, CHUANG, T. C., SHARIFF, A. R. M., AHMAD, Noordin. Multi-Threshold Technique for Segmentation of Satellite Imagery for Feature Extraction. GISDevelopment.net, 2002 [online] Disponível na Internet via WWW. URL: <http://www.gisdevelopment.net/technology/ip/index.htm>. Arquivo capturado em 02 de março de 2003.
- [39] Manual do Matlab
- [40] MARQUES FILHO, Ogê, NETO, Hugo Vieira. Processamento Digital de Imagens. Rio de Janeiro: Brasport, 1999.
- [41] MENESES, P. R., NETTO, J. da S. M. Sensoriamento Remoto – Reflectância dos alvos naturais. EMBRAPA. Brasília, DF: UnB; Planaltina: Embrapa Cerrados, 2001.
- [42] MOURA, Gevilacio A. Coêlho de. Citações e referências a documentos eletrônicos. [online] Disponível na Internet via WWW. URL: http://www.quatrocantos.com/tec_web/refere/7exemp.htm Arquivo capturado em 26 de novembro de 2001.
- [43] MUEHE, Dieter, VALENTINI, Enise. O litoral do Estado do Rio de Janeiro – uma caracterização físico-ambiental. Programa de Pós-Graduação em Geografia da UFRJ. [livro online]. Disponível na Internet via WWW. URL: http://www.ppgg.igeo.ufrj.br/livros/dieter/litoral_rio_68.pdf. Arquivo capturado em 13 de julho de 2004.
- [44] NASA – National Administration Space Agency. Earth Observatory Library: Remote Sensing. [online] Disponível na Internet via WWW. URL: <http://earthobservatory.nasa.gov/Library/RemoteSensing/>. Arquivo capturado em 20 de janeiro de 2004.
- [45] NASA – National Administration Space Agency. Landsat 7 – Science Data Users Handbook. [online] Disponível na Internet via WWW. URL: http://tpwww.gsfc.nasa.gov/IAS/handbook/handbook_toc.html Arquivo capturado em 14 de dezembro de 2000.

- [46] NASA – *National Administration Space Agency. Landsat 7 Gateway - Landsat 7 Project.* [online] Disponível na Internet via WWW. URL: <http://landsat.gsfc.nasa.gov/> . Arquivo capturado em 25 de abril de 2002.
- [47] NASA – *National Administration Space Agency. NASA's Earth Sciences Program.* [online] Disponível na Internet via WWW. URL: <http://rst.gsfc.nasa.gov/Front/tofc.html> . Arquivo capturado em 20 de junho de 2002.
- [48] NASCIMENTO JR, C. L., YONEYAMA, T. Inteligência Artificial em Controle e Automação. 1ª edição. São Paulo: Editora Edgard Blücher LTDA, 2000.
- [49] NISHIDA, Waleska. Uma Rede Neural Artificial para Classificação de Imagens Multiespectrais de Sensoriamento Remoto. Dissertação de Mestrado em Engenharia de Produção. Centro Tecnológico da Universidade Federal de Santa Catarina. Florianópolis, fevereiro de 1998. [online] Disponível na Internet via WWW. URL: <http://www.eps.ufsc.br/disserta98/waleska/>. Arquivo capturado em 14 de outubro de 2003.
- [50] PESCHEL, Joshua M. Creating Land Cover Input Datasets for the SWAT 2000 Model Using Remotely Sensed Data. Department of Civil Engineering. Texas A&M University. . [online] Disponível na Internet via WWW. URL: <http://ceprofs.tamu.edu/folivera/TxAgGIS/Spring2002/Peschel/peschel.htm> . Arquivo capturado em 13 de agosto de 2004.
- [51] PONS, X.; SOLÉ-SUGRAÑES, L. A simple radiometric correction model to improve automatic mapping of vegetation from multispectral satellite data. *Remote Sensing of Environment*. Vol. 48, n° 2, p.191-204. New York, 1994.
- [52] Portal Ambiente Brasil. [online] Disponível na Internet via WWW. URL: <http://www.ambientebrasil.com.br/composer.php3?base=./estadual/index.html&conteudo=./estadual/rj.html>. Arquivo capturado em 05 de maio de 2004.
- [53] Portal do Centro de Informações e Dados do Rio de Janeiro – CIDE. [online] Disponível na Internet via WWW. URL: <http://www.cide.rj.gov.br/download/territorio/territorios.asp>. Arquivo capturado em 30 de março de 2004.
- [54] Research Systems, Inc. ENVI User's Guide - Version 3.2. July, 1999.

- [55] ROCHA, César H. Barra. Geoprocessamento: Tecnologia Transdisciplinar. Juiz de Fora, MG: Ed. do Autor, 2000.
- [56] SANGTHONGPRAOW, U., THITIMAJSHIMA, P., RANGSANSERI, Y. Modified Fuzzy C-Means for Satellite Image Segmentation. GISDevelopment.net, 1999 [online] Disponível na Internet via WWW. URL: <http://www.gisdevelopment.net/aars/acrs/1999/ts11/>. Arquivo capturado em 02 de março de 2003.
- [57] SCHAEFFER-NOVELLI, Yara. Avaliação e Ações Prioritárias para a Conservação da Biodiversidade da Zona Costeira e Marinha. Grupo de Ecossistemas: Manguezal, Marisma e Apicum. Programa Nacional da Biodiversidade – PRONABIO. Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira – PROBIO. São Paulo, Brasil, 1999. [online] Disponível na Internet via WWW. URL: <http://www.bdt.fat.org.br/workshop/costa/mangue/>. Arquivo capturado em 25 de agosto de 2004.
- [58] SCHALKOFF, Robert J. Pattern recognition: Statistical Structural and Neural Approachs. USA: John Wiley & Sons, Inc., 1992.
- [59] SCHOWENGERDT, Robert A. Remote Sensing – Models and methods for image processing. 2nd ed. USA: Academic Press, 1997.
- [60] SCHWARTZ, W. R., PEDRINI, H. Método para Classificação de Imagens Baseada em Matrizes de Co-ocorrência Utilizando Características de Textura. Anais do III Colóquio Brasileiro de Ciências Geodésicas (CBCG'2003), pp. 1-11 Curitiba-PR, 06-09 maio de 2003. [online] Disponível na Internet via WWW. URL: http://pet.inf.ufpr.br/~william/public_pt.html. Arquivo capturado em 04 de maio de 2004.
- [61] SHAW, I. S., SIMÕES, M. G. Controle e Modelagem Fuzzy. 1^a edição. São Paulo: Editora Edgard Blücher LTDA, 1999.
- [62] SHAW, Ian S., SIMÕES, Marcelo Godoy. Controle e Modelagem Fuzzy. FAPESP. São Paulo: Editora Edgard Blücher, 1999.
- [63] SWAIN, P. H., DAVIS, S. M. (editors). Remote Sensing: The Quantitative Approach. USA: McGraw-Hill, 1978.
- [64] TEIXEIRA, Karla dos Santos. Estudo Comparativo de Métodos de Classificação Digital não-Supervisionada em Imagens do Satélite LANDSAT7.

Monografia de conclusão do Curso de Especialização em Geotecnologias Aplicadas à Análise Ambiental de Bacias Hidrográficas. PGTIGA: UFF, 2002.

- [65] TONG, C. S., ZHANG, Y., ZHENG, N. Variation-Based Image Segmentation and its Multiscale Realizations. International Conference on Inverse Problems, Jan 9-12, 2002. [online] Disponível na Internet via WWW. URL: <http://www.math.hkbu.edu.hk/~cstong/mainpage.htm>. Arquivo capturado em 22 de julho de 2003.
- [66] TOU, J. T., GONZALEZ, R. C. Pattern Recognition Principles. Massachusetts: Addison-Wesley, 1974.
- [67] VALENTE, Roberta de O. A., VETTORAZZI, Carlos A. Mapeamento de uso e cobertura do solo da Bacia do Rio Corumbataí, SP. Circular Técnica nº 196, de maio de 2003, IPEF. [online] Disponível na Internet via WWW. URL: <http://www.ipef.br/publicacoes/ctecnica/>. Arquivo capturado em 13 de outubro de 2003.
- [68] VERGARA, O. R.; KURKDJIAN, M. L. N. O.; D'ALGE, J. C. L.; PEREIRA, M. N. Conteúdo informativo e exatidão geométrica de dados TM-Landsat analógicos para a atualização de cartas topográficas. XVIII Congresso Brasileiro de Cartografia, Rio de Janeiro, 1997. [online] Disponível na Internet via WWW. URL: <http://www.dpi.inpe.br/~julio/>. Arquivo capturado em 11 de agosto de 2003.
- [69] VERMOTE, E.F., TANRE, D., DEUZE, J.L., HERMAN, M., MORCRETTE, J.J. Second simulation of the satellite signal in the solar spectrum, 6S: An overview. IEEE Trans. Geosc. and Remote Sens., 35(3), 1997, p.675-686.
- [70] VIEIRA, Carlos A. O. Técnicas de Classificação Não-Supervisionada em Imagens Digitais Multiespectrais. Dissertação de Mestrado em Sistemas e Computação. Instituto Militar de Engenharia. Rio de Janeiro, abril de 1993.
- [71] ZIMBACK, Célia Regina Lopes. Classificação de Imagens no IDRISI. Grupo de Estudos e Pesquisas Agrárias Georreferenciadas – GEPAC. Faculdade de Ciências Agrônômicas – FCA. Universidade Estadual Paulista – UNESP. Botucatu, junho de 2003. [online] Disponível na Internet via

WWW. URL: <http://www.fca.unesp.br/departam/recnat/docentes/Celia/Sensor.%20Remoto.htm>. Arquivo capturado em 16 de agosto de 2004.

- [72] ZULLO JR, Jurandir, GU, Xing Fa, GUYOT, Gerard, LAMPARELLI, Rubens, BEZERRA, Paulo César. Pré-processamento das imagens de satélite. Caderno de Informações Georreferenciadas – CIG. Volume 1 – Número 1 – Artigo 7, 1996. [online] Disponível na Internet via WWW. URL: <http://orion.cpa.unicamp.br/revista/ciqv1n1a7.html>. Arquivo capturado em 05 de março de 2003.

ANEXO

CONCEITOS BÁSICOS UTILIZADOS

Os seguintes conceitos básicos foram inseridos de forma a dirimir dúvidas acerca dos termos que se encontram nesta dissertação.

Algoritmo: Conjunto finito de regras e operações, bem definidas e ordenadas, destinadas à solução de um problema, ou de uma classe de problemas, na qual é estipulado, com generalidade e sem restrições, regras formais para a obtenção do resultado, ou da solução do problema.

Alvo: qualquer objeto ou classe de interesse de estudo.

Ambiente: Espaço que cerca ou envolve objetos.

Classe: Conjunto constituído por um ou mais objetos de mesmo significado.

Classificação digital de imagem: Técnicas que identificam e distribuem em classes os dados de uma imagem, segundo um determinado ordenamento, ou método, implementado na forma de algoritmos em meio computacional. Como resultado obtém-se uma imagem onde cada *pixel* da mesma é mapeado para um tema ou classe, que será expressa por cores ou símbolos.

Conjunto de dados; ver Espaço dos dados.

Dado: elemento informativo não associado a atributos de valor.

Espaço: é a região de domínio de um conceito, de uma definição, de um evento ou de uma função.

Espaço dos dados: nesta dissertação, é o conjunto de todos os dados da imagem. Logo, são todos os valores quantizados da radiância média incidente no sensor na área correspondente a cada *pixel* da imagem, representados em forma de matriz, para seu armazenamento em formato digital.

Fenômeno: Fato ou ocorrência passível de observação.

Geoprocessamento: Tecnologia transdisciplinar que utiliza, primordialmente, ferramentas computacionais para tratamento, processamento, análise e apresentação de dados geográficos.

Imagem: Toda aquela obtida pelo processamento analógico dos registros digitais.

Informação: é o significado atribuído pelo intelecto humano a determinado dado ou a um conjunto de dados.

Inteligência Artificial: Ramo da Ciência da Computação dedicado a desenvolver equivalentes computacionais de processos peculiares à cognição humana, como, a produção de inferências lógicas, o aprendizado, a compreensão de linguagem natural e o reconhecimento de padrões.

Lógica difusa ou nebulosa ou fuzzy: lógica onde as variáveis podem adquirir graus intermediários de veracidade ou falsidade, representados por valores fracionários entre 0 e 1, o que permite modelar graus de incerteza.

Método: Conjunto de técnicas dispostas convenientemente e ordenadamente para alcançar um fim.

Metodologia: Estudo científico de métodos visando um objetivo.

Objeto: Tudo que é material e perceptível por qualquer dos sentidos.

Objeto geográfico: Objeto cujas características espaciais estão associadas ao meio ambiente.

Posição: Referência espacial de um objeto.

Processo: Implementação de um conjunto de tecnologias.

Processamento digital de imagens: Conjunto de métodos físico-matemáticos para análise, correção e manipulação dos *pixels* constantes do registro digital de uma cena.

Pixel : É o menor elemento de uma imagem (em inglês **P**icture **E**lement → *pixel*).

Radiância: É a energia radiante resultante incidente no coletor do sensor.

Reconhecimento de Padrões: técnicas que objetivam a análise e classificação de objetos ou classes.

Redes Neurais Artificiais: técnicas computacionais que simulam o comportamento do cérebro humano, adquirindo conhecimento através da experiência.

Sensoriamento Remoto: Análise dos sinais detectados por sensores com a finalidade precípua de extrair inferências de objetos distantes ou não acessíveis.

Significado: representação de um objeto.

Sistemas Especialistas: são algoritmos computacionais baseados em conhecimento que utilizam técnicas de IA para a realização de inferências baseadas em regras e em dados fornecidos.

Técnica: Conjunto de processos destinados à uma produção utilitária.

Tecnologia: Transformação do conhecimento humano em produto.

Tema: área de estudo e representação de objetos e feições que atendam à propriedades específicas. Podem abarcar uma ou mais classes. Exemplo: topografia, navegação aérea, etc.

Tratamento Digital de Imagem: Processo de supressão dos ruídos indesejáveis e de realce dos sinais julgados importantes para a aplicação, significando ser este um processo extremamente subjetivo, na medida em que é dependente dos critérios do observador.