



Universidade do Estado do Rio de Janeiro

Karla dos Santos Teixeira


Uma proposta metodológica de integração de técnicas de análise espectral e de inteligência computacional, baseadas em conhecimento, para o reconhecimento de padrões em imagens multiespectrais

Rio de Janeiro

2012

Karla dos Santos Teixeira

Uma proposta metodológica de integração de técnicas de análise espectral e de inteligência computacional, baseadas em conhecimento, para o reconhecimento de padrões em imagens multiespectrais



Tese apresentada, como requisito parcial para obtenção do título de Doutor, ao Programa de Pós-graduação em Meio Ambiente, da Universidade do Estado do Rio de Janeiro. Área de concentração: Monitoramento e Controle Ambiental.

Orientadora: Prof.^a Dra. Liane Maria Azevedo Dornelles

Rio de Janeiro

2012

CATALOGAÇÃO NA FONTE
UERJ / REDE SIRIUS / BIBLIOTECA CTC/A

T266 Teixeira, Karla dos Santos.

Uma proposta metodológica de integração de técnicas de análise espectral e de inteligência computacional, baseadas em conhecimento, para o reconhecimento de padrões em imagens multiespectrais / Karla dos Santos Teixeira – 2012.

136 p.

Orientadora: Prof^a. Dr^a. Liane Maria Azevedo Dornelles.

Tese (Doutorado) – Universidade do Estado do Rio de Janeiro, Instituto de Biologia Roberto Alcântara Gomes.

1. Reconhecimento de padrões – Teses. 2. Análise espectral - Teses. 3. Inteligência artificial - Teses. 4. Sensoriamento Remoto - Teses. I. Dornelles, Liane Maria Azevedo. II. Universidade do Estado do Rio de Janeiro. Programa de Pós-Graduação em Meio Ambiente. III. Título.

CDU 004.8:910.2

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta tese, desde que citada a fonte.

Assinatura

Rio de Janeiro, RJ, 01 / 05 / 2013

Data

Karla dos Santos Teixeira

Uma proposta metodológica de integração de técnicas de análise espectral e de inteligência computacional, baseadas em conhecimento, para o reconhecimento de padrões em imagens multiespectrais

Tese apresentada, como requisito para obtenção do título de Doutor, ao Programa de Pós-Graduação em Meio Ambiente, da Universidade do Estado do Rio de Janeiro. Área de concentração: Monitoramento e Controle Ambiental.

Aprovado em 18 de dezembro de 2012.

Banca examinadora:



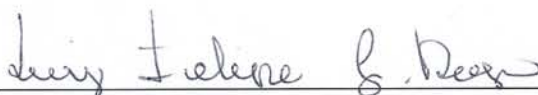
Prof.^a. Dr.^a. Liane Maria Azevedo Dornelles (Orientadora)
Instituto de Geografia – UERJ



Prof. Dr. Gilberto Pessanha Ribeiro
Faculdade de Engenharia – UERJ



Prof.^a. Dr.^a. Nadja Maria Castilho da Costa
Instituto de Geografia – UERJ



Prof. Dr. Luiz Felipe Guanaes Rego
Departamento de Geografia – PUC-RIO



Prof. Dr. Luiz Henrique Aguiar de Azevedo
SENSORIA

Rio de Janeiro
2012

DEDICATÓRIA

Ao meu marido, Ivan de A. Medina, pelo amor e apoio irrefragáveis.

“A amizade é um amor que nunca morre”.

“Amor não é se envolver com a pessoa perfeita, aquela dos nossos sonhos. Não existem príncipes nem princesas. Encare a outra pessoa de forma sincera e real, exaltando suas qualidades, mas sabendo também de seus defeitos. O amor só é lindo, quando encontramos alguém que nos transforme no melhor que podemos ser”.

Mário Quintana

AGRADECIMENTOS

Aos meus pais, Helio e Isis, pela paciência e compreensão pelas minhas ausências constantes para a realização deste trabalho.

Aos professores e colegas (principalmente aos de minha turma de 2008 – “Os Complexados”) do Programa de Pós-Graduação em Meio Ambiente da UERJ, pela amizade e companheirismo, mas principalmente pela oportunidade única de convívio e enriquecedora troca de experiências, advindas de diversas áreas de conhecimento (Oceanografia, Educação, Geografia, História, Direito, Química, Biologia e Arquitetura), proporcionando uma importante e significativa ampliação do meu horizonte de estudos.

A minha cara orientadora, Prof^a. Liane Maria Azevedo Dornelles, pelo incentivo, compreensão, apoio incondicional, firmeza e extrema precisão em palavras e ações.

À cara Prof^a. María Elena Iannarelli, com Notório Saber pela SELPER – Sociedade Latinoamericana de Especialistas em Sensoriamento Remoto, pela disposição e paciência em ensinar, compartilhando o seu amplo conhecimento em interpretação visual de imagens com esta engenheira, bem como pela feitura da verdade terrestre da área-teste utilizada nesta tese.

Ao Instituto de Pesquisas da Marinha – IPqM, principalmente aos colegas que incentivaram sempre minha aspiração de realizar esta tese. Aos diretores C. Alte (EN) Eduardo *Maculan* Vicentini, C. Alte (EN) *Maurillo* Euclides F. da Silva e C. Alte (EN) Humberto Moraes *Ruivo* agradeço as permissões concedidas para a realização deste doutorado em tempo parcial. Agradecimento especial aos CMG (EN) Guilherme da Silva *Sineiro* e CC (EN) *André Chaves* Mendes pelo suporte na concretização deste trabalho e incentivo na linha de pesquisa que almejo dentro do instituto.

Ao Instituto Nacional de Pesquisas Espaciais – INPE pela incrível iniciativa de disponibilizar gratuitamente as cenas do satélite LANDSAT, mediante prévio cadastro na sua página da Internet.

Ao Instituto de Geografia da UERJ, na pessoa do diretor Prof. Glaucio J. Marafon, que permitiu minhas entradas no LabGeo para a utilização do programa IDRISI Taiga.

Ao Centro de Recursos IDRISI, para os países de língua portuguesa, representante oficial da Clark Labs, localizado no Laboratório de Geoprocessamento do Centro de Ecologia da Universidade Federal do Rio Grande do Sul – UFRGS, que fornece apoio aos usuários do IDRISI, na pessoa do seu coordenador, Prof. Heinrich Hasenack, que despendeu horas de seu tempo para atender minhas dúvidas sobre o IDRISI Taiga.

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

Se queres receber, deves primeiro dar: eis o início da inteligência.

Tau-te-King

Entendo por razão, não a faculdade de raciocinar, que pode ser bem ou mal utilizada, mas o encadeamento das verdades que só pode produzir verdades, e uma verdade não pode ser contrária a outra.

Wilhelm Leibniz

Aquilo a que chamamos acaso não é, e não pode deixar de ser, senão a causa ignorada de um efeito conhecido.

Voltaire

Para sabermos bem as coisas, é preciso sabermos os pormenores, e como estes são quase infinitos, os nossos conhecimentos são sempre superficiais e imperfeitos.

François La Rochefoucauld

Saber é compreender como é que a mais insignificante das coisas está ligada ao todo; nada existe por si só.

Alain (pseudo. de Émile-Auguste Chartier)

Use a teoria para proporcionar um insight; use o bom senso e intuição onde estes sejam adequados. O equilíbrio não pode ser alcançado a não ser que se tenha tanto bom senso como habilidade com a teoria.

David Gries

A mera formulação de um problema, frequentemente, é muito mais essencial do que a sua solução, que pode ser simples questão de habilidade matemática ou experimental.

Albert Einstein

RESUMO

TEIXEIRA, Karla dos Santos. *Uma proposta metodológica de integração de técnicas de análise espectral e de inteligência computacional, baseadas em conhecimento, para o reconhecimento de padrões em imagens multiespectrais*. 136 p. Tese (Doutorado em Meio Ambiente) – Universidade do estado do Rio de Janeiro, 2012.

Somente no ano de 2011 foram adquiridos mais de 1.000TB de novos registros digitais de imagem advindos de Sensoriamento Remoto orbital. Tal gama de registros, que possui uma progressão geométrica crescente, é adicionada, anualmente, a incrível e extraordinária massa de dados de imagens orbitais já existentes da superfície da Terra (adquiridos desde a década de 70 do século passado). Esta quantidade maciça de registros, onde a grande maioria sequer foi processada, requer ferramentas computacionais que permitam o reconhecimento automático de padrões de imagem desejados, de modo a permitir a extração dos objetos geográficos e de alvos de interesse, de forma mais rápida e concisa. A proposta de tal reconhecimento ser realizado automaticamente por meio da integração de técnicas de Análise Espectral e de Inteligência Computacional com base no Conhecimento adquirido por especialista em imagem foi implementada na forma de um integrador com base nas técnicas de Redes Neurais Computacionais (ou Artificiais) (através do Mapa de Características Auto-Organizáveis de Kohonen – SOFM) e de Lógica Difusa ou *Fuzzy* (através de Mamdani). Estas foram aplicadas às assinaturas espectrais de cada padrão de interesse, formadas pelos níveis de quantização ou níveis de cinza do respectivo padrão em cada uma das bandas espectrais, de forma que a classificação dos padrões irá depender, de forma indissociável, da correlação das assinaturas espectrais nas seis bandas do sensor, tal qual o trabalho dos especialistas em imagens. Foram utilizadas as bandas 1 a 5 e 7 do satélite LANDSAT-5 para a determinação de cinco classes/alvos de interesse da cobertura e ocupação terrestre em três recortes da área-teste, situados no Estado do Rio de Janeiro (Guaratiba, Mangaratiba e Magé) nesta integração, com confrontação dos resultados obtidos com aqueles derivados da interpretação da especialista em imagens, a qual foi corroborada através de verificação da verdade terrestre. Houve também a comparação dos resultados obtidos no integrador com dois sistemas computacionais comerciais (IDRISI Taiga e ENVI 4.8), no que tange a qualidade da classificação (índice Kappa) e tempo de resposta. O integrador, com classificações híbridas (supervisionadas e não supervisionadas) em sua implementação, provou ser eficaz no reconhecimento automático (não supervisionado) de padrões multiespectrais e no aprendizado destes padrões, pois para cada uma das entradas dos recortes da área-teste, menor foi o aprendizado necessário para sua classificação alcançar um acerto médio final de 87%, frente às classificações da especialista em imagem. A sua eficácia também foi comprovada frente aos sistemas computacionais testados, com índice Kappa médio de 0,86.

Palavras-chave: Assinatura espectral. Classificação não supervisionada. Inteligência computacional. Sensoriamento remoto. Interpretação visual. LANDSAT-5. Imagem de satélite.

ABSTRACT

Only in 2011 were acquired over 1.000TB of new digital image registers arising from orbital remote sensing. This range of data, which has a geometric progression increasing, is added annually to an extraordinary and incredible mass of data from existing satellite images of Earth's surface (acquired since the 70s of last century). This massive amount of raw data requires computational tools which allow the automatic recognition of image patterns desired to allow the extraction of geographical objects and targets of interest more quickly and concisely. The proposal for such recognition to be performed automatically through Spectral Analysis and Computational Intelligence integration, based on knowledge acquired by image experts, was implemented as an integrator based on Computational Neural Networks (via Kohonen's Self-Organizing Feature Maps - SOM) and Fuzzy Logic (through Mamdani) techniques. These techniques were applied to the spectral signatures – pattern formed by the quantization levels or gray levels of the corresponding pattern in each spectral band – of each pattern of interest, so that the pattern classification will depend, in an inseparable manner, of the spectral signatures correlation of the six bands of the sensor, like the work of image experts. Bands 1 to 5 and 7 of the Landsat-5 satellite were used for the determination of five classes / targets of interest in cover and land occupation, in three test areas located in the State of Rio de Janeiro (Guaratiba, Mangaratiba and Magé) in this integration with comparison of results with those derived from the interpretation of the imaging expert, which was corroborated by checking the ground truth. There was also a results comparison obtained with two commercial computer systems (IDRISI Taiga and ENVI 4.8) with the integrator, regarding the quality of classification (Kappa) and response time. The integrator, with hybrid classifications (supervised and unsupervised) in its implementation, proved to be effective in multispectral automatic (unsupervised) pattern recognition and in learning of these patterns, because as the input of a new test area occurs, the lower became the process of learning, which achieve a final average accuracy of 87%, compared to the expert's classifications. Its efficacy was also demonstrated compared to systems tested, with average Kappa of 0.86.

Keywords: Spectral signature. Unsupervised classification. Computational intelligence. Remote sensing. Visual interpretation. LANDSAT-5. Satellite image.

LISTA DE FIGURAS

Figura 1	- Processo de obtenção de imagens por SR (FLORENZANO, 2002, p. 9).....	22
Figura 2	- Espectro eletromagnético (HOWSTUFFWORKS, 2001).	22
Figura 3	- Sistema RGB – sistema aditivo de cores (adaptada de AZEVEDO; CONCI, 2003, p. 191).....	23
Figura 4	- Satélite LANDSAT-5 (LANDSAT, 2011).	25
Figura 5	- Representação de um pixel mistura em uma imagem LANDSAT (ALVES, 2004).	39
Figura 6	- Reservatório preenchido com 100% de água (A); reservatório preenchido com 50% de água (B); e reservatório preenchido com 0% de água (C).	43
Figura 8	- Esquema de um neurônio computacional (GSI, 1999).	49
Figura 9	- Grade do satélite LANDSAT sobre parte da região sudeste do Brasil, com realce da órbita/cena selecionada em vermelho (modificada de GOOGLE EARTH, 2012).	55
Figura 10	- Informações da cena 217/76 escolhida (parcial INPE, 2011).	56
Figura 11	- Cena 217/76 do LANDSAT-5 com realce, em rosa, dos recortes das imagens 1A, 1B e 1C.	58
Figura 12	- Tela do IDRISI para feitura do recorte 1A – Guaratiba.	59
Figura 13	- Recorte 1A, Guaratiba, da cena analisada, com composição R3G4B5. Escala aproximada: 1:250.000.	60
Figura 14	- Bairros da cidade do Rio de Janeiro no recorte 1A – Guaratiba (modificada CIDE, 2009).....	61
Figura 15	- Recorte 1A com realce de características gerais da área.....	62
Figura 16	- Recorte 1B, Mangaratiba, da cena analisada, com composição R5G4B3. Escala aproximada: 1:250.000.	62
Figura 17	- Realce de características gerais da área do recorte 1B – Mangaratiba (modificado de WASSERMAN, 2005).	63
Figura 18	- Recorte 1C, Magé, da cena analisada, com composição R4G5B7. Escala aproximada: 1:250.000.	64
Figura 19	- Recorte 1C com realce de características gerais da área.....	65
Figura 20	- Fluxograma de trabalho realizado pela especialista em imagens para a geração das classificações e para a análise espectral.	70
Figura 21	- Tela do programa IDRISI com as funções STRECTH, HISTO e COMPOSITE.	72
Figura 22	- Realce dos 30 pixels escolhidos para cada classe na cena analisada.	73
Figura 23	- Tela do IDRISI com as funções CLUSTER e ISOCLUST.....	76
Figura 24	- Função ISODATA e K-MEANS no ENVI.	79
Figura 25	- Esquema da integração proposta (modificada de TEIXEIRA, 2010, p. 386) ...	81

Figura 26	- Processo de extração de assinatura espectral proposta (adaptada TEIXEIRA, 2010, p. 386).....	84
Figura 27	- Exemplo de máscara 3x3 dos vizinhos mais próximos de um pixel da classe Manguezal.	85
Figura 28	- Fluxograma de trabalho para implementação do integrador.	87
Figura 29	- Banco de Assinaturas Espectrais (BAE) implementado no Excel, com parte da classe Florestal na guia aberta.....	89
Figura 30	- Tela do MATLAB utilizada para a geração do MRNC com a topologia.	90
Figura 31	- Tela do MATLAB com o treinamento da rede.	90
Figura 32	- MLD implementado no MATLAB.	91
Figura 33	- Tela do MLD com as funções de pertinência da banda 4, com o detalhe para os parâmetros da função água não particulada.....	92
Figura 34	- Tela da função de saída do MLD implementado.	93
Figura 35	- Esquema de trabalho do algoritmo do MTD.....	94
Figura 36	- Fluxograma dos testes do integrador.....	95
Figura 37	- Os pontos de controle em cada recorte: (a) 1A – Guaratiba (90 pontos); (b) 1B – Mangaratiba (75 pontos); e (c) 1C – Magé (75 pontos).	98
Figura 38	- Classificações do recorte 1A – Guaratiba: (a) da especialista; (b) do IDRISI (ISOCLUST); (c) do ENVI (ISODATA); e (d) do integrador.....	100
Figura 39	- Classificações do recorte 1B – Mangaratiba : (a) da especialista; (b) do Idrisi (ISOCLUST); (c) do ENVI (ISODATA); e (d) do integrador.	103
Figura 40	- Classificações do recorte 1C – Magé : (a) da especialista; (b) do Idrisi (ISOCLUST); (c) do ENVI (ISODATA); e (d) do integrador.	104
Figura 41	- Imagem da classificação da especialista para o recorte 1A – Guaratiba da área-teste.	127
Figura 42	- Imagem da classificação da especialista para o recorte 1B – Mangaratiba da área-teste.	127
Figura 43	- Imagem da classificação da especialista para o recorte 1C – Magé da área-teste.	128
Figura 44	- Imagem da classificação realizada pela função CLUSTER no IDRISI para o recorte 1A – Guaratiba da área-teste.....	129
Figura 45	- Imagem da classificação realizada pela função ISOCLUST no IDRISI para o recorte 1A – Guaratiba da área-teste.....	129
Figura 46	- Imagem da classificação realizada pela função CLUSTER no IDRISI para o recorte 1B – Mangaratiba da área-teste.....	130
Figura 47	- Imagem da classificação realizada pela função ISOCLUST no IDRISI para o recorte 1B – Mangaratiba da área-teste.....	130
Figura 48	- Imagem da classificação realizada pela função CLUSTER no IDRISI para o recorte 1C – Magé da área-teste.....	131

Figura 49	- Imagem da classificação realizada pela função ISOCLUST no IDRISI para o recorte 1C – Magé da área-teste.....	131
Figura 50	- Imagem da classificação do ISODATA pelo ENVI para o recorte 1A – Guaratiba da área-teste.....	132
Figura 51	- Imagem da classificação da K-MEANS pelo ENVI para o recorte 1A – Guaratiba da área-teste.....	132
Figura 52	- Imagem da classificação do ISODATA pelo ENVI para o recorte 1B – Mangaratiba da área-teste.	133
Figura 53	- Imagem da classificação do K-MEANS pelo ENVI para o recorte 1B – Mangaratiba da área-teste.	133
Figura 54	- Imagem da classificação do ISODATA pelo ENVI para o recorte 1C – Magé da área-teste.	134
Figura 55	- Imagem da classificação do K-MEANS pelo ENVI no recorte 1C – Magé da área-teste.	134
Figura 56	- Classificação do recorte 1A – Guaratiba pelo integrador.	135
Figura 57	- Classificação do recorte 1B – Mangaratiba pelo integrador.	135
Figura 58	- Classificação do recorte 1C – Magé pelo integrador.	136

LISTA DE QUADROS

Quadro 1	- Faixas espectrais (bandas) do sensor TM do satélite LANDSAT-5.....	26
Quadro 2	- Exemplo dos elementos de interesse para a cena LANDSAT-5, utilizada pela especialista nas áreas-teste, composição R5G4B3.....	70
Quadro 3	- Qualidade da classificação analisada associada aos valores do índice Kappa (LANDIS; KOCH, 1977).	97
Quadro 4	- Tabela de cores para as classificações analisadas.....	99
Quadro 5	- Quadro comparativo da análise das classificações realizadas pela especialista, pelos sistemas IDRISI e ENVI, e pelo integrador para a área-teste 1A - Guaratiba.	101
Quadro 6	- Quadro comparativo da análise das classificações realizadas pela especialista, pelos sistemas IDRISI e ENVI, e pelo integrador para a área-teste 1A - Guaratiba.	102
Quadro 7	- Quadro comparativo da análise das classificações realizadas pela especialista, pelos sistemas IDRISI e ENVI, e pelo integrador para a área-teste 1A - Guaratiba.	105
Quadro 8	- Índices Kappa das classificações realizadas pelo integrador, pela especialista e pelos sistemas IDRISI e ENVI.	107
Quadro 9	- Mostra do comportamento das assertivas do integrador implementado frente às classificações da especialista para cada um dos recortes da cena analisada.	108

LISTA DE ABREVIATURAS, SIGLAS E ACRÔNIMOS

AE	Análise Espectral
APA	Área de Proteção Ambiental
BAE	Banco de Assinaturas Espectrais
BDAE	Banco de Dados de Assinaturas Espectrais
CBERS	<i>China-Brazil Earth Resources Satellite</i> (Satélite Sino-Brasileiro de Recursos Terrestres)
CFI	Classes Fora de Interesse
CT	<i>Change Threshold</i> (limiar de alteração de classe)
ENVI	<i>Environment for Visualizing Images</i>
ESEC	Estação Ecológica
GeoTIFF	<i>Geographic Tagged Image File Format</i>
GIMP	<i>GNU Image Manipulation Program</i>
GNU GPL	<i>General Public License</i>
HS	<i>Hyperspectral Sensor</i> (Sensor Hiperespectral)
HSI	<i>Hyperspectral Sensor Imaging</i> (Imageamento advindo de Sensor Hiperespectral)
IBGE	Instituto Brasileiro de Geografia e Estatística
IC	Inteligência Computacional
INPE	Instituto Nacional de Pesquisas Espaciais
LANDSAT	<i>Land Remote Sensing Satellite</i>
LD	Lógica Difusa (<i>Fuzzy Logic</i>)
MATLAB	<i>Matrix Laboratory</i>
MaxVer	Máxima Verossimilhança
MLD	Módulo de Lógica Difusa (<i>Fuzzy</i>)
MRNC	Módulo de Redes Neurais Computacionais (ou Artificiais)
MS	<i>Multispectral Sensor</i> (Sensor Multiespectral)

MSI	<i>Multispectral Sensor Imaging</i> (Imageamento advindo de Sensor Multiespectral)
MTD	Módulo Tomador de Decisão
NASA	<i>National Aeronautics and Space Administration</i>
PDI	Processamento Digital de Imagens
Pixel	<i>Picture x Element</i> (elemento da figura)
RAM	<i>Random Access Memory</i>
RGB	Red – Green – Blue
RNC	Redes Neurais Computacionais (ou Redes Neurais Artificiais – RNA)
SIG	Sistema de Informação Geográfica (<i>Geographic Information System</i> – GIS)
SOM	<i>Self Organizing Maps</i> (Mapas Auto-Organizáveis de Kohonen)
SOFM	<i>Self Organizing Feature Maps</i> (Mapas de Características Auto-Organizáveis de Kohonen)
SPRING	Sistema de Processamento de Informações Georreferenciadas
SR	Sensoriamento Remoto
USGS	<i>United States Geological Survey</i>

SUMÁRIO

	INTRODUÇÃO	16
1	REVISÃO BIBLIOGRÁFICA	21
1.1	Sensoriamento Remoto (SR)	21
1.1.1	Programa LANDSAT	25
1.1.2	Complexidade	27
1.2	Processamento Digital de Imagens (PDI)	29
1.2.1	Interpretação de imagens	31
1.2.2	Sistemas de classificação de imagens	32
1.2.3	Análise espectral	35
1.2.4	Pixel mistura	39
1.3	Inteligência Computacional (IC)	40
1.3.1	Lógica difusa	42
1.3.2	Rede Neural Computacional (RNC)	46
2	MATERIAIS E MÉTODOS	53
2.1	Cena escolhida para análise	53
2.1.1	<u>Parâmetros</u>	53
2.1.2	<u>Localização e caracterização da área-teste</u>	56
2.1.3	<u>Recortes 1A, 1B e 1C</u>	57
2.1.3.1	Recorte 1A – Guaratiba	60
2.1.3.2	Recorte 1B – Mangaratiba	62
2.1.3.3	Recorte 1C – Magé	64
2.2	Definição e caracterização das classes em estudo	65
2.2.1	<u>Interpretação visual</u>	68
2.3	Sistema computacional IDRISI	74
2.4	Sistema computacional ENVI	77
2.5	Integração proposta	79
2.5.1	<u>Complexidade da cena</u>	79
2.5.2	<u>Integração proposta</u>	80
2.5.2.1	Análise espectral realizada	83
2.6	Implementação e teste do integrador	86
2.6.1	<u>Implementação do integrador</u>	86
2.6.1.1	Banco de Assinaturas Espaciais (BAE)	88
2.6.1.2	Módulo de Redes Neurais Computacionais (MRNC)	89
2.6.1.3	Módulo de Lógica Difusa (MLD)	91
2.6.1.4	Módulo Tomador de Decisão (MTD)	93
2.6.2	<u>Teste do integrador</u>	95
2.6.3	<u>Avaliação das classificações</u>	95
3	RESULTADOS	99
3.1	Avaliação visual das classificações dos sistemas IDRISI e ENVI versus classificações da especialista versus integrador	99
3.1.1	<u>Recorte 1A – Guaratiba</u>	100

3.1.2	<u>Recorte 1B – Mangaratiba</u>	102
3.1.3	<u>Recorte 1C – Magé</u>	104
3.2	Avaliação das classificações dos sistemas IDRISI e ENVI versus classificações da especialista versus integrador segundo o índice Kappa e tempo de processamento	106
3.3	Discussão dos resultados	108
4	CONCLUSÕES	111
	REFERÊNCIAS	115
	BIBLIOGRAFIA	126
	APÊNDICE A – Classificações da especialista em imagem	127
	APÊNDICE B – Classificações do sistema IDRISI Taiga.....	129
	APÊNDICE C – Classificações do sistema ENVI.....	132
	APÊNDICE D – Classificações do integrador	135

INTRODUÇÃO

“A imagem vale por mil palavras”. Este clichê ou dito popular está cada vez mais presente nos tempos atuais onde se verifica a existência de câmeras em celulares, em computadores, em sinais de trânsito, em ruas – para controle e vigilância – dentre inúmeras outras. Tal profusão de câmeras é devida à atual tecnologia de imageamento, que está se tornando irremediavelmente ao método eletrônico digital. A capacidade de resolução das câmeras fotográficas digitais dobra em menos de um ano e, prevê-se que, até meados da próxima década, não mais existirão as câmeras analógicas, inclusas as aerofotogramétricas. Por outro lado, é praticamente inconcebível o número de registros digitais a serem obtidos futuramente por sensores aéreos e orbitais de diferentes resoluções radiométricas. Ingressamos, indiscutivelmente, na era dos registros digitais.

Como, em essência, o imageamento capta a informação espectral de uma cena (LILLESAND; KIEFER, 1994), os registros digitais encerram a informação espectral do estado de cada um dos objetos da cena, no instante da captação. Os sensores multiespectrais orbitais de imageamento possuem diversas gamas de faixas espectrais, além da faixa do visível, o que eleva mais ainda a quantidade de dados espectrais (registros digitais) disponível sobre os objetos da cena. Portanto, estes dados contêm informações que são imprescindíveis para a caracterização incontestável destes objetos, conduzindo à necessidade do conhecimento dos padrões espectrais (assinaturas nas diversas bandas) ser significativo para uma correta classificação dos mesmos (GONZALES; WOODS, 2000).

Os sensores multiespectrais (até seis dezenas de bandas) e hiperespectrais (acima de seis dezenas de bandas), instalados em plataformas orbitais de imageamento, permitem a ampliação do poder discriminatório e da caracterização de alvos ou classes de interesse dentre os padrões, objetos ou feições presentes (LILLESAND; KIEFER, 1994; SCHOWENGERDT, 1997). Ocorre que tal ampliação não é verificada na medida em que todas estas bandas não são plenamente utilizadas pelos principais sistemas computacionais comerciais ora em uso (TEIXEIRA, 2004; BLASCHKE; KUX, 2007).

Análise de imagens ou a interpretação de imagens (conhecida também como Fotointerpretação, quando esta era baseada essencialmente em fotografias aéreas) advindas de sensores diversos, inclusive os orbitais, é um processo onde é realizada a identificação, análise e caracterização dos objetos (“leitura” da imagem) de uma porção de superfície geográfica (CONWAY, 1967), de forma visual, por um ou mais profissionais, com base em seu conhecimento adquirido e em dados, se possível, disponíveis da área. Tais profissionais,

denominados de especialistas ou peritos ou expertos em imagens (chamados, antigamente, de fotointérpretes), realizam este processo através de um raciocínio lógico, indutivo e dedutivo, baseados em experiência e competência acumuladas, para a compreensão e explicação dos objetos, feições e condições presentes, bem como das relações espaciais existentes entre estes (TEIXEIRA, 2008, 2010).

O processo de interpretação dos especialistas pode demandar um longo tempo de trabalho, se for realizado sem ajuda computacional, ou um tempo menor com a utilização de recursos computacionais. Normalmente, os especialistas possuem larga experiência profissional na área de fotointerpretação pura, o que conduz a um refinamento intrínseco da interpretação de imagens multiespectrais, na medida em que os registros digitais são utilizados como um dos elementos básicos visuais de reconhecimento, além da tonalidade, cor, textura, tamanho, forma e sombra (ANDERSON, 1982; CONWAY, 1967).

Além dos especialistas, existem outros profissionais, chamados de analistas de imagem, que não possuem grande experiência em fotointerpretação (conhecimento básico de interpretação visual), efetuando a classificação dos objetos baseada, essencialmente, em sistemas computacionais comerciais, possuindo um grande conhecimento de operação do sistema, sem, no entanto, conhecimento formal dos algoritmos utilizados na classificação por estes sistemas (os algoritmos são considerados “caixas-pretas”, protegidos por patente) (TEIXEIRA, 2008).

Para qualquer um dos profissionais citados – especialistas e analistas – o trabalho efetuado tem, geralmente, dois resultados possíveis: aquele obtido rapidamente com uma qualidade de interpretação inferior, ou aquele com uma boa qualidade de interpretação, mas com um grande dispêndio de tempo. Em qualquer um dos resultados, tem-se sempre perda, seja de qualidade ou de tempo. Urge, então, a necessidade do desenvolvimento de ferramentas computacionais que possibilitem extrair de forma mais rápida e precisa as informações desejadas dos registros digitais multiespectrais – as assinaturas espectrais (TEIXEIRA, 2004, 2008, 2010).

Observa-se que os especialistas em imagens estão se tornando uma classe em extinção, havendo cada vez mais analistas de imagens e muito menos especialistas sendo formados, representando um desaparecimento, em progressão geométrica, do conhecimento do especialista, uma perda lastimável para a feitura de sistemas especialistas em imagem, bem como para a ciência como um todo.

Desde o final do século passado verifica-se a utilização, contínua e geometricamente crescente, dos registros digitais, advindos, principalmente, de sensores imageadores orbitais voltados fundamentalmente para o reconhecimento automático de padrões de feições

geográficas e para o inventário de recursos naturais. Além disso, a cada ano, novos sensores, com maior poder resolutivo (tanto qualitativo, quanto quantitativo) são lançados, o que está tornando a gama de dados disponível muito superior à capacidade de processá-los (TEIXEIRA, 2010).

Ao mesmo tempo, verifica-se que a extração de dados de interesse desta enorme massa ainda é realizada de forma quase que rudimentar, pois é trabalhada, essencialmente, por especialistas (profissionais com centenas de horas de experiência em análise de imagem) e analistas em imagens, que norteiam o processamento (seja este totalmente computacional ou uma combinação entre eles, sendo este último o mais comum atualmente) e revisam os resultados alcançados pelos sistemas comerciais disponíveis no mercado, havendo um grande dispêndio de tempo, em favor de um melhor resultado na classificação final dos dados desejados. Verifica-se, portanto, a necessidade premente do desenvolvimento de ferramentas computacionais que possibilitem extrair de forma mais rápida e precisa tais dados, mas com a mínima interferência humana possível (TEIXEIRA, 2004, 2008).

Atualmente, as alterações sofridas pelo meio ambiente terrestre, sejam estas antrópicas (intervenções humanas) ou naturais, ocorrem de forma constante, efêmera e com uma tal rapidez, que leva a uma premente necessidade do conhecimento, o mais completo possível, das assinaturas espectrais dos objetos ou feições geográficas de interesse, de forma a se obter uma caracterização mais precisa e rápida possível (MENESES; NETTO, 2001). Portanto, este conhecimento é essencial para a realização de avaliação de impactos ambientais, inventário e manejo de recursos naturais, previsão de safra e controle de pragas, classificação de alvos militares, dentre variadas outras aplicações e áreas.

As dimensões continentais, as poucas explorações, mapeamentos e cadastramentos das mesmas, bem como os vastos recursos naturais existentes nas terras brasileiras exigem uma monitorização constante do território, somente possível através da utilização de sistemas de apoio baseados em alta tecnologia. Tais sistemas nortearão a tomada de decisão para supervisão e patrulhamento do território brasileiro, com o objetivo precípuo de preservação de sua soberania e de suas riquezas (IBGE, 2006). Segundo IBGE (2006, p. 9) “o conhecimento sobre o uso da terra ganha relevo pela necessidade de garantir a sua sustentabilidade diante das questões ambientais, sociais e econômicas a ele relacionadas e trazidas à tona no debate sobre o desenvolvimento sustentável”.

Desta forma, um sistema classificador que trabalhe com vários registros digitais, na forma de assinaturas espectrais, permitindo a adição e a aprendizagem de conhecimento dos comportamentos espectrais de objetos e feições de interesse, a partir da entrada de novos registros digitais dos objetos geográficos de interesse, gerando classificações não

supervisionadas destes objetos, é extremamente desejável, vantajoso e de grande valia, pois irá propiciar uma rápida e confiável análise de cenas multiespectrais.

A presente tese tem por objetivo a proposição de uma integração de técnicas de Análise Espectral e de Inteligência Computacional, baseada em Conhecimento de especialista em imagem, para a classificação automática de objetos geográficos de interesse a partir da comprovação da eficácia da integração proposta, com base na implementação de um integrador; da realização de um estudo comparativo dos métodos de classificação digital não supervisionada em imagens de sensores orbitais multiespectrais; bem como da comparação dos resultados obtidos por estes sistemas e o integrador implementado.

Esta integração contribui para diversas áreas do conhecimento (devido a multidisciplinaridade do tema Sensoriamento Remoto) tais como Engenharia, Geologia, Geografia, Biologia, Gestão, Administração, Agricultura, Pecuária, GeoInteligência e Defesa, abrangendo, assim, tanto a comunidade científica, como a área militar (Defesa Estratégica), além da área comercial e de serviços públicos, pois qualquer tipo de classe ou padrão, que possua registros digitais multiespectrais, poderá ser detectada.

O desenvolvimento da integração proposta, fruto de pesquisa nacional, pode fornecer uma possível solução para tal lacuna, assegurando a independência tecnológica do Brasil neste âmbito: questão extremamente importante em relação a soberania nacional, principalmente porque o atualíssimo tema sobre Defesa Nacional envolve tanto a Amazônia, quanto a Amazônia Azul, ambas áreas muito visadas por interesses multinacionais. A relevância desta integração é acentuada quando se considera que os sistemas computacionais comerciais de classificação automática existentes, em realidade são sistemas semiautomáticos (ainda necessitando de expertos nas classes ou alvos desejados para o norteamento de grande parte do trabalho realizado pelos algoritmos), e todos estrangeiros, além de serem extremamente dispendiosos em custo e em tempo.

A integração proposta pode ser utilizada tanto para o diagnóstico ambiental, como para o mapeamento, pois ela pode ser implementada de forma a se tornar um módulo ou parte integrante de um Sistema de Informação Geográfica (SIG), pois os objetos geográficos ou alvos de interesse classificados poderão ser integrados ao respectivo banco de dados do SIG, proporcionando um incremento nos dados disponíveis.

Esta tese é dividida da seguinte forma:

- O capítulo um apresenta os resultados da revisão bibliográfica realizada durante todo o trabalho de tese, com os principais conceitos envolvidos, as referências relevantes, além do estado da arte da classificação de padrões em imagens multiespectrais;

- O capítulo dois trata dos materiais e métodos, representados pela seleção da cena da área-teste, os recortes realizados na mesma, com os consequentes realces e composições associados; os sistemas computacionais comerciais de mais largo emprego utilizados em Sensoriamento Remoto e demais recursos computacionais e não computacionais utilizados; a definição e caracterização das classes em estudo; a explicitação da integração proposta contendo a análise espectral realizada, o conhecimento da especialista em imagens, a complexidade da cena multiespectrais, os algoritmos selecionados, a implementação da integração proposta, o teste da mesma e a forma estipulada para a avaliação dos resultados;
- No capítulo três são contemplados os resultados obtidos na presente tese, englobando os testes realizados, as classificações executadas pela especialista em imagens, além dos resultados obtidos pelos sistemas computacionais comerciais e pela integração proposta;
- O capítulo quatro apresenta as conclusões encontradas e as recomendações de trabalhos futuros;
- As referências listam todas as fontes citadas neste documento e a bibliografia apresenta as fontes consultadas que nortearam este trabalho de tese; e
- As classificações da especialista em imagem são apresentadas no Apêndice A. O mesmo ocorre para as classificações do IDRISI Taiga no Apêndice B, as classificações do ENVI no Apêndice C e as do integrador no Apêndice D.

1 REVISÃO BIBLIOGRÁFICA

Consiste na apresentação de alguns dos conceitos básicos em relação ao Sensoriamento Remoto e do Processamento Digital de Imagens (PDI), como também os conceitos básicos, as referências relevantes e o atual estado da arte em relação à Inteligência Computacional (IC) relacionadas a cenas multiespectrais, advindas de satélites orbitais, para a classificação da cobertura ou ocupação do solo da superfície terrestre, que nortearam a integração proposta. Tal mostra é importante para a consolidação dos argumentos a serem apresentados, permitindo familiarização dos termos aos leitores iniciantes nessa área, bem como, aos que já os conhecem com mais profundidade, possam ser direcionados aos tópicos principais deste estudo.

1.1 Sensoriamento Remoto (SR)

O termo Sensoriamento Remoto (SR) foi cunhado nos anos 60 do século passado por um artigo não publicado pelo Grupo de Geografia do *Office of Naval Research* (ONR), através da pesquisa de outros instrumentos, além das câmeras fotográficas, como radiômetros e *scanners* que abrangiam outras regiões do espectro eletromagnético: o termo fotografia estava se tornando muito limitado, pois, segundo seus radicais, significa desenhar ou escrever com luz (JENSEN, 2009).

Entre os variados conceitos de SR existentes (JENSEN, 2009; NOVO, 2008), o conceito proposto por Avery e Berlin (1992) é um dos mais sucintos e diretos, descrito como sendo um conjunto de técnicas para obtenção de dados sobre objetos da superfície terrestre com a coleta através de instrumentos que não estejam em contato direto com os objetos. Garcia (1982) cita que há que haver uma restrição quanto a estas técnicas serem restritas a sensores que capturem somente a energia eletromagnética.

Assim, a Figura 1 ilustra o processo de obtenção de imagens via sensoriamento remoto orbital.




Figura 1 - Processo de obtenção de imagens por SR (FLORENZANO, 2002, p. 9).

A origem do SR se iniciou por volta de 1858 quando Gaspard Felix Tournachon tirou uma fotografia aérea a partir de um balão. O sensoriamento remoto orbital se iniciou na década de 60 do século passado com o início do projeto dos satélites que formariam a série LANDSAT, iniciando-se, assim, a era da aquisição sistemática de imagens da superfície terrestre (JENSEN, 2009).

A radiação eletromagnética é o veículo que permite a existência do SR, sendo o espectro eletromagnético a representação desta radiação (Figura 2).




Figura 2 - Espectro eletromagnético (HOWSTUFFWORKS, 2001).

O olho humano é somente sensível à luz visível deste espectro, com as colorações básicas vermelho, verde e azul as componentes do sistema chamado RGB (*Red – Green – Blue*), como apresentado na Figura 3. Este sistema é representativo do sistema de cores

aditivas, utilizado em televisão e monitores, onde “a cor é gerada pela mistura de vários comprimentos de onda luminosa provocando uma sensação de cor quando atinge o olho” (AZEVEDO; CONCI, 2003).

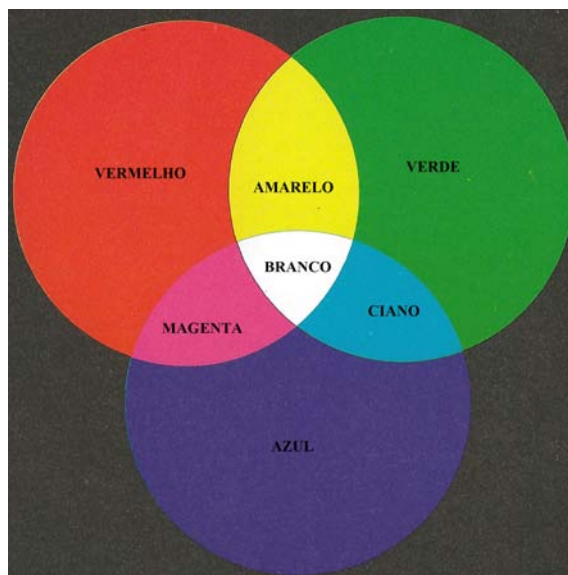


Figura 3 - Sistema RGB – sistema aditivo de cores (adaptada de AZEVEDO; CONCI, 2003, p. 191).

Todos os objetos presentes na superfície terrestre, como a vegetação e a água, absorvem, refletem e transmitem a radiação eletromagnética em determinadas proporções variantes com o comprimento de onda dos tipos de radiações envolvidas e das características bio-físico-químicas do objeto (FLORENZANO, 2002), como também do ambiente no qual ele se situa. Sobre este assunto, a citação de Jensen (2009) é muito importante:

Certas regiões ou bandas espectrais do espectro eletromagnético são ótimas para obter informações sobre parâmetros biofísicos. As bandas são normalmente selecionadas para maximizar o contraste entre o objeto de interesse e o seu substrato (i. e., o contraste objeto-substrato). A seleção cuidadosa das bandas espectrais pode melhorar a probabilidade de que a informação desejada vá ser extraída do sensor remoto (JENSEN, 2009, p. 16).

As imagens advindas de sensores a bordos de satélites possuem características específicas, a saber:

- Resolução espectral é número de intervalos de comprimentos de onda do espectro eletromagnético (também chamados de bandas ou canais espectrais) que um sensor possui (JENSEN, 2009);
- Resolução espacial é o tamanho do menor elemento imageado na superfície terrestre, que irá formar o pixel (*picture x element*) da imagem a ser formada; é referida à resolução do sensor, tratando-se “do campo de visada instantâneo (Ifov), ou seja, refere-se a área vista por determinado sensor sobre a superfície

da Terra dentro de um ângulo sólido, em dado instante de tempo” (MOREIRA, 2005, p. 123).

- Resolução radiométrica é a capacidade de um sensor em distinguir as pequenas variações da radiação eletromagnética captada, expressas pelas potências do fluxo radiante resultante de entrada, que serão reamostradas com a posterior quantização destas em níveis de cinza (JENSEN, 2009); e
- Resolução temporal é o menor intervalo de tempo para aquisição de duas imagens de uma mesma porção da superfície terrestre.

O desenvolvimento do poder computacional dos computadores, bem como os avanços das técnicas de PDI e dos sensores orbitais, proporcionaram a disponibilização de uma grande e geometricamente crescente gama de imagens, o que transformou o SR em um recurso imprescindível em atividade que se utilize de dados geográficos, como inventários de recursos naturais e levantamentos cartográficos (LILLESAND; KIEFER, 1994): estamos na era da supervalorização positiva do SR. Atualmente tais dados são imprescindíveis em qualquer atividade humana, seja ela política, econômica, social ou cultural. Consequentemente, tal difusão impulsionou a pesquisa e o desenvolvimento de algoritmos cada vez mais rápidos e confiáveis para o processamento das imagens orbitais, gerando um moto contínuo, que culminou no “emprego de ferramentas inteligentes de análise que dispensem a intervenção humana, ou que a reduza a um mínimo” (TEIXEIRA, 2004, p. 9).

Os atuais sistemas de SR instalados em plataformas orbitais estão se tornando equipamentos estratégicos imprescindíveis, principalmente no que tange à aquisição de dados da superfície terrestre de áreas de difícil acesso ou inóspita, com escalas tanto global como local, assim como com cobertura repetitiva (TEIXEIRA, 2008).

A atual visão globalizada das questões ambientais tem concorrido para a crescente demanda por informações geográficas e cartográficas, obtidas em ritmo cada vez mais intenso graças ao desenvolvimento de tecnologias e técnicas, apoiadas tanto na utilização de computadores, quanto nas imagens obtidas por sensores orbitais e aerotransportados, isto é, instalados a bordo de satélites espaciais e de veículos aéreos. Tais imagens, por possuírem características de repetitividade e de periodicidade, tornaram-se também dados indispensáveis na análise e monitorização multitemáticas e multitemporais dos fenômenos naturais ou daqueles decorrentes de ações antrópicas em nosso planeta (PONZONI; SHIMABUKURO, 2009).

1.1.1 Programa LANDSAT

A missão LANDSAT (*LAND Remote Sensing SATellite* ou Satélite para Sensoriamento Remoto do Terreno) foi iniciada em meados dos anos 60, com o objetivo específico de observação dos recursos naturais da Terra, sendo, então, denominada de *Earth Resources Technology Satellite* (ERTS), sendo gerenciada pela NASA (*National Aeronautics and Space Administration*) e pelo USGS (*United States Geological Survey*). O primeiro satélite foi lançado em 1972 e somente em 1975, com o lançamento do segundo satélite, é que passou a ser denominado de LANDSAT (LANDSAT, 2011).

O objetivo principal do sistema LANDSAT é prover, temporalmente, imagens de alta qualidade, seja na banda espectral do visível, quanto na do infravermelho, de todas as massas de terra e de água da superfície da Terra, de forma a se ter um sistema de banco de dados constantemente atualizado. Os dados de entrada deste sistema deverão ser suficientemente consistentes com os dados já cadastrados, em termos de geometria, calibração, área coberta e características espectrais das imagens, de forma a permitir a comparação destas para fins de caracterização e detecção de alterações regionais e globais (LANDSAT, 2011; JENSEN, 2009).

O LANDSAT-5 (Figura 4), lançado em março de 1984, é o único ativo até a presente data, o que representa mais de 28 anos em funcionamento fornecendo imagens contínuas da Terra.




Figura 4 - Satélite LANDSAT-5 (LANDSAT, 2011).

O Instituto Nacional de Pesquisas Espaciais (INPE) está disponibilizando as cenas do satélite LANDSAT de forma gratuita, mediante cadastro e aceite dos termos de utilização das mesmas, através de sua página na *Internet* (INPE, 2011). Tal atitude abnegada está gerando a disseminação do uso das imagens advindas de sensores remotos orbitais, principalmente nas escolas e universidades, proporcionando o aumento das pesquisas e dos estudos em Sensoriamento Remoto.

O LANDSAT-5 possui órbita repetitiva, circular, heliosíncrona quase polar (com cobertura completa da Terra entre 81°N e 81°S), com altitude de 705 km, velocidade aproximada de 7,7 km/s (no solo), ciclo orbital de 16 dias e faixa de área de 185 km, recortadas em cenas de 185 km X 185 km, sendo cada uma imageada em 24 s (EMBRAPA, 2008). O Quadro 1 -apresenta as faixas espectrais utilizadas por este satélite.

Bandas do sensor	Comprimento de onda (μm)	Resolução espacial (m)
1	0,45 - 0,52	30
2	0,52 - 0,60	30
3	0,63 - 0,69	30
4	0,76 - 0,90	30
5	1,55 - 1,75	30
6	10,40 - 12,50	120
7	2,08 - 2035	30

Quadro 1 - Faixas espectrais (bandas) do sensor TM do satélite LANDSAT-5.

As bandas deste sensor utilizadas foram (INPE, 2012):

- Banda 1 – faixa espectral: azul – está inserida dentro da faixa do espectro visível ao olho humano, com grande penetração em corpos de água, com elevada transparência, o que permite estudos batimétricos; a clorofila e carotenóides absorvem esta faixa espectral; sensibilidade a plumas de fumaça ou atividade industrial;
- Banda 2 – faixa espectral: verde – também está inserida dentro da faixa do espectro visível ao olho humano, possuindo boa penetração em corpos de água, com sensibilidade à presença de sedimentos em suspensão, permitindo análise qualitativa e quantitativa;
- Banda 3 – faixa espectral: vermelho – também inserida dentro da faixa do espectro visível ao olho humano, com grande absorção pela vegetação verde, uniforme e densa, o que gera contrastes interessantes com diferentes tipos de cobertura vegetal; boa para delimitação de mancha urbana; pode ser utilizada para identificação de áreas agrícolas;
- Banda 4 – faixa espectral: infravermelho próximo – grande absorção pelos corpos de água; com grande refletância em áreas de vegetação densa e uniforme; sensibilidade ao dossel Florestal e à morfologia do terreno; permite

a análise e mapeamento de feições geológicas e estruturais; pode ser utilizada para identificação de áreas agrícolas;

- Banda 5 – faixa espectral: infravermelho médio – sensibilidade a quantidade de umidade nas plantas – desequilíbrio hídrico;
- Banda 6 – faixa espectral: infravermelho termal – apresentando grande sensibilidade aos fenômenos relativos aos contrastes térmicos, servindo na detecção das propriedades termais de solos, rochas, água e vegetação; e
- Banda 7 – faixa espectral: infravermelho distante – sensibilidade à morfologia do terreno – geomorfologia, solos e geologia.

1.1.2 Complexidade

Segundo uma abordagem filosófica, *complexidade* é a visão do mundo como um todo indissociável, sendo a formação do conhecimento construída, conseqüentemente, segundo uma abordagem multidisciplinar. A complexidade é um tema bastante intrincado, de difícil percepção, devido aos diversos fatores e aspectos envolvidos. A teoria semiótica da complexidade estuda a aplicação dos conceitos da semiótica na análise dos sinais no domínio das ciências exatas e da terra, que é o caso em tela.

Charles Sanders Peirce foi matemático e filósofo, do século XIX e XX, que estudou profundamente os sinais, os signos e seus processos. A Semiótica (palavra que vem do grego *semeiotiké*, que significa a arte dos sinais) é a ciência geral dos signos e da semiose (processo dos sinais), estudando todos os fenômenos culturais como se fossem sistemas de signos, de significação. Logo, ela estuda o processo de significação ou de representação, na natureza e na cultura, do conceito ou da idéia, tendo por objeto qualquer sistema que contenha signos – imagens (artes visuais, fotografia e cinema), gestos, música, religião (ritos), vestuário, ciência, dentre outros mais. A Semiótica também é chamada de Semiologia, possuindo ambos os mesmos significados. Como o português é uma língua rica, e já se sabe que semiótica é a arte dos sinais, então Semiologia (semio = sinal, e logia = discurso, estudo, ciência, linguagem) seria melhor conceituada como a ciência dos signos e sinais (FERREIRA, 2004; GUDWIN; GOMIDE, 2006).

Segundo Morin, Ciurana e Motta (2007), a complexidade é composta de sete princípios básicos:

- a) **Sistêmico ou organizacional:** o conhecimento é visto como um sistema composto por elementos ou partes. O filósofo, físico e matemático Blaise Pascal já considerava, no séc. XVII, que o conhecimento do todo e das partes é essencial para o conhecimento completo de um sistema. Ocorre que a soma do conhecimento dos elementos não é igual ao conhecimento do todo, e vice-versa, o que nos leva a também conhecer particularmente as inter-relações e interdependências entre as partes, e destas com o todo;
- b) **Hologramático:** baseia-se no mesmo princípio de um holograma, onde se tem o "todo em cada parte" (isto é, cada parte contém informações completas ou quase completas acerca da totalidade) proporciona uma maneira inteiramente nova de entender a organização e a ordem da natureza. Um objeto ou um sistema, em um nível mais profundo da realidade, possui partes ou partículas não como entidades individuais, mas como extensões da mesma coisa fundamental, do todo. Logo, estas partículas não são partes separadas do todo, mas sim facetas de uma Unidade, mais profunda e mais subliminar do que o estimado ou imaginado, nos levando a pensar no Universo como uma projeção, um holograma. Assim sendo, conclui-se que a separação das partes, das partículas é uma ilusão e, em nível mais profundo da realidade, que todas as coisas do Universo estão infinitamente interconectadas e inter-relacionadas;
- c) **Retroatividade:** onde se rompe com o princípio linear causa-efeito, com a causa agindo sobre o efeito, mas, também, o efeito retroage sobre a causa, o que permite uma “autonomia organizacional do sistema” (MORIN; CIURANA; MOTTA, 2007, p. 35). Assim posto, existe as retroações negativas, que funcionam como um mecanismo de estabilização do sistema, e as positivas, que rompem com a regulação do sistema e ampliam determinada tendência ou desvio para uma nova situação (incerteza);
- d) **Recursividade:** há uma dinâmica autoprodutiva e auto-organizacional, em que “os efeitos ou produtos, são, simultaneamente, causadores e produtores do próprio processo, no qual os estados finais são necessários para a geração dos estados iniciais” (MORIN; CIURANA; MOTTA, 2007, p. 35);

- e) Autonomia/dependência: introduz a idéia de que, para manter sua autonomia, qualquer organização necessita interagir com o ecossistema que o circunda, o que se traduz em múltiplas interdependências; p. ex., a captação de energia implica em uma conseqüente transformação do ecossistema;
- f) Dialógico: é aquele onde ocorrem as associações complexas das instâncias “conjuntamente necessárias à existência, ao funcionamento e ao desenvolvimento de um fenômeno organizado” (MORIN, CIURANA e MOTTA, 2007, p. 36): é avaliar e analisar as lógicas presentes no fenômeno analisado; e
- g) Reintrodução do sujeito cognoscente em todo conhecimento: significando relevar o papel do observador, de quem está construindo a realidade, pois ele está organizando e criticando o conhecimento, mesmo estando inserido nesta realidade que tenta conhecer. O sujeito constrói a realidade que o cerca com base nos princípios anteriores.

1.2 Processamento Digital de Imagens (PDI)

O PDI tem a função de desenvolver e utilizar técnicas para identificar, extrair, condensar e realçar as informações de interesse em uma imagem (GONÇALVES, 1997).

As operações de pré-processamento são procedimentos de retificação e restauração de imagens para corrigir distorções ou degradações originadas no processo de aquisição ou transmissão da imagem, sendo os procedimentos mais utilizados as correções radiométricas, as correções geométricas e a remoção de ruídos (LILLESAND; KIEFER, 1994).

As correções radiométricas são técnicas existentes que alteram os níveis de quantização dos pixels (ou níveis de cinza) de uma imagem de forma a corrigir distorções em seus valores, como aquelas causadas pelas condições atmosféricas, geometria da visão ou erros radiométricos ocorridos devido a defeitos no funcionamento do próprio sensor imageador (LILLESAND; KIEFER, 1994). Ruídos em imagem são falhas apresentadas por um ou mais detectores presentes no sensor gerando falta de informações da energia captada de uma área da superfície terrestre, sendo caracterizados pela presença de níveis de quantização muito diferentes dos pixels vizinhos, sendo uma das técnicas de remoção a substituição do valor de radiância do pixel problemático pela média da radiância dos pixels das linhas superior e inferior da imagem (MOREIRA, 2005). Obviamente que após a aplicação de tal

técnica não é possível se garantir a confiabilidade da informação deste pixel. As correções geométricas reorganizam os pixels da imagem em relação a um determinado sistema de projeção cartográfica, para minimizar as distorções geométricas, provenientes das variações decorrentes do movimento do sensor em volta da terra e das próprias características do mesmo (LUIZ *et al.*, 2003).

O realce de imagens são técnicas aplicadas de forma a proporcionar a alteração das imagens para torná-las mais apropriadas à visão humana (os elementos de uma imagem tem as suas definições aumentadas através do aumento do contraste – deslocamento dos níveis de quantização dos pixels), pois a análise visual desempenha um dos aspectos mais importantes do sensoriamento remoto (EASTMAN, 2006). Geralmente, as bandas das cenas advindas de sensoriamento remoto tendem a ser escuras e apresentar baixo contraste principalmente aquelas adquiridas no intervalo do espectro visível, pois os comprimentos de onda são os que mais sofrem interferência dos efeitos atmosféricos. Assim sendo, as operações de realce de contraste (ampliação do contraste) permitem a expansão da variabilidade dos valores de brilho representativos de uma imagem, melhorando o seu contraste, facilitando a interpretação visual dos alvos da cena (JENSEN, 2009).

A utilização de composições coloridas (falsa-cor) é fundamentada pelo fato de que o olho humano, não treinado, é capaz de discriminar mais facilmente cores do que tons de cinza. Assim, para cada banda é associada uma cor primária (vermelho/*red* – R, verde/*green* – G ou azul/*blue* – B) e a partir da combinação destas são produzidas as cores secundárias (Figura 3, p. 27), como ciano (verde + azul), magenta (vermelho + azul), amarelo (vermelho + verde) e branco (vermelho + verde + azul). Conforme são associadas as cores RGB às bandas, os alvos serão representados por uma ou mais cores secundárias, gerando diferentes opções de composições coloridas (MOREIRA, 2005).

Além dessas opções, com a finalidade de melhorar a extração de determinados alvos de interesse, o especialista também pode realizar operações de transformação de bandas espectrais, como, por exemplo, a aplicação de filtros espaciais, a geração de índices de vegetação, a análise de componentes principais, dentre variadas outras: cada uma dessas operações irá produzir uma nova imagem ou um novo conjunto de imagens a partir do conjunto dos dados originais.

1.2.1 Interpretação de imagens

Consiste na identificação dos objetos presentes em uma imagem com a consequente significação destes objetos, pois qualquer imagem advinda de sensor remoto, independentemente de escala ou de resolução, apresenta elementos básicos para análise e interpretação das quais é possível a extração de dados para a geração de informação e conhecimento (FLORENZANO, 2002).

A experiência do especialista ou perito ou experto em imagem, também chamado pelo antigo nome de fotointérprete, é a determinante para a eficiência na identificação dos objetos, temas, classes, padrões ou alvos de interesse. Este profissional se baseia nos valores ou padrões espectrais (níveis de quantização dos pixels), na cor ou tonalidade, na textura, no tamanho, na forma, na sombra, na altura e localização como os elementos básicos da interpretação visual de imagens. Além disso, se utiliza de mapas, tabelas, sistemas computacionais, dados ambientais da região e todo e qualquer material que norteie a compreensão do comportamento de cada objeto ou de um determinado conjunto de objetos contidos na imagem analisada. Todo este processo envolve raciocínio lógico, indutivo e dedutivo, decorrentes do conhecimento e da competência acumulada do especialista para a compreensão e explicação dos objetos, feições e condições presentes, bem como das relações espaciais existentes entre estes (TEIXEIRA, 2008, 2010).

Teixeira (2004, p. 8) relata que “as imagens obtidas por sensores multiespectrais orbitais necessitam ser lidas e interpretadas por especialistas, os quais são expertos 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, inerente à formação dos especialistas em imagem que necessitam de vários anos de estudo, aprendizado e aplicação, sendo estes caracterizados pela 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” (TEIXEIRA, 2004, p. 8).

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 a campo (Teixeira, 2004, p. 8).

Portanto o êxito da análise e consequente interpretação de imagens dependem exclusivamente da experiência do especialista. A importância da interpretação visual é muito bem explicada pelo seguinte texto de Jensen (2009):

O processo de interpretação visual de uma foto ou imagem exige não apenas conhecimento científico, mas todo o conhecimento que uma pessoa obteve durante toda a sua vida. Tal aprendizado não pode ser medido, programado, ou entendido completamente. A sinergia da combinação do conhecimento científico com a experiência de mundo real do analista permite ao intérprete desenvolver métodos heurísticos práticos para extrair informações importantes de uma imagem. É conhecido o fato de que alguns analistas de imagens são superiores a outros analistas de imagens porque eles: 1) entendem melhor os princípios científicos, 2) tem maior experiência de campo e viram muitos objetos da paisagem e áreas geográficas, e/ou 3) podem sintetizar princípios científicos e experiências do mundo real para chegarem a conclusões lógicas e corretas (JENSEN, 2009, p. 5 e 7).

O método comparativo de interpretação de imagens advindas de sensores orbitais consiste na interpretação dos dados com base em uma chave de interpretação elaborada em função da quantização dos pixels (níveis de cinza) ou em função das cores resultantes de composições coloridas nas imagens. Dentre este método, o método seletivo é aquele onde a chave de interpretação só apresenta os alvos ou classes de interesse de ocupação do solo, aqueles que não interessam ao estudo ou trabalho não são individualizados na interpretação, sendo estes últimos agrupados em uma única classe temática, a qual geralmente é denominada de Outros (MOREIRA, 2005).

1.2.2 Sistemas de classificação de imagens

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.

A classificação digital de imagem tem 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 (LILLESAND; KIEFER, 1994).

Lillesand e Kiefer (1994) apresenta que regras de decisão baseadas somente em radiâncias espectrais espelham uma classificação chamada de reconhecimento de padrões espectrais. Por outro lado, as tais regras de decisão podem ser baseadas em figuras geométricas, medidas e padrões, sendo, então, este procedimento chamado de reconhecimento

de padrões espaciais. Em ambos os casos, todos os pixels de uma imagem serão categorizados em temas (classes ou alvos).

Na classificação dita supervisionada ou assistida ou não automática 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 ou na imagem em análise. Para tal, são estipuladas áreas de teste (ou amostras ou fronteiras de classe ou assinaturas) a fim de compilar a “chave” de interpretação numérica que define a assinatura espectral de cada tipo de feição de interesse, caracterizando a necessidade de conhecimento prévio da área estudada. 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) (LILLESAND; KIEFER, 1994; SCHOWENGERDT, 1997). Observa-se que a utilização de tais classificadores deve ser realizada por especialistas em imagens, pois estes sistemas, ao não requererem estudos ou conhecimentos prévios das áreas em análise para o refinamento da classificação, realizam análises bem menos pormenorizadas. Assim, a principal vantagem de classificações não supervisionadas é a de proporcionar uma visão macro da cobertura ou ocupação do solo da região, no menor tempo possível, mas com o auxílio imprescindível de um especialista. Tal fato proporcionou a possibilidade de realização do trabalho de uma equipe de especialistas – processo artesanal e demorado – ser efetuado por somente um especialista com o auxílio de um único computador, obviamente, com uma menor riqueza de detalhes, mas com o dispêndio bem menor de tempo (TEIXEIRA, 2004, 2010).

Em se tratando de uma classificação não supervisionada ou não assistida ou automática, cada um dos pixels de uma imagem ou cena é, primeiramente, classificado através da agregação destes em agrupamentos espectrais (*clusters*) baseados em similaridades, determinadas somente pelas funções matemáticas descritoras das propriedades inerentes às classes pesquisadas (SCHOWENGERDT, 1997). Tal classificação é utilizada quando não se conhece a região em estudo, e se necessita de uma identificação rápida da área. Logo, é necessária a presença de um especialista ou um analista em imagens para realizar esta identificação (TEIXEIRA, 2010). A existência de diversos métodos de classificação não supervisionada acarreta incerteza, principalmente em usuários não experientes, acerca de qual método ser o mais adequado à área ou ao objeto geográfico ou alvo em estudo, tanto em termos de tempo despendido, quanto no que diz respeito à qualidade dos resultados obtidos pela classificação (JENSEN, 2009). Tais incertezas geram consumo de tempo com estudos, testes e verificações na busca do método mais favorável, cabendo ressaltar, no entanto, que,

quando da análise conjugada de mais de uma classe, nem sempre serão obtidos resultados satisfatórios para todas as classes investigadas (TEIXEIRA, 2004, 2008).

Deve ser ressaltado que a escolha de classificações não supervisionadas se deve, essencialmente, ao fato que estas não necessitam de nenhum conhecimento prévio da área, além de fornecer, em um tempo razoavelmente curto, uma visão global das classes de objetos geográficos nela contidos. Isto proporciona uma destacada serventia frente às classificações supervisionadas (ou assistidas ou não automáticas), já que estas demandam usuários experientes – os especialistas em imagens ou os analistas de imagens – tanto na área em estudo quanto no uso do sistema computacional utilizado, além de implicarem no dispêndio de tempo de processamento computacional, devido a uma série de ajustes de parâmetros de imagem, necessários para o aprimoramento dos resultados finais das classificações (TEIXEIRA, 2010).

A classificação híbrida consiste em uma fusão das técnicas de classificação não supervisionada com as de classificação supervisionada. Este tipo de classificação apresenta resultados finais condizentes com a verdade terrestre que a não supervisionada e em menor tempo que a supervisionada (RODRIGUES; RESENDE; TIMOSZCZUK, 2007).

Os algoritmos dos classificadores dividem-se em duas abordagens distintas: os classificadores pixel-a-pixel que utilizam somente do dado espectral de cada pixel; e os classificadores por região que utilizam, além do dado espectral de cada pixel, os dados espaciais do pixel com os seus vizinhos (FLORENZANO, 2002).

Observa-se que os sistemas comerciais existentes, bem como as metodologias utilizadas para a classificação de padrões em imagens multiespectrais, são todos frutos de conhecimento estrangeiro, que as detém sob a forma de patente, não podendo ser detalhadas devido ao sigilo. Os dois únicos expoentes nacionais são o SPRING – Sistema de Processamento de Informações Georreferenciadas, atualmente na versão 5.2 (em 2012), e o TerraView, versão 4.2.1 (agosto de 2012), um aplicativo construído sobre a biblioteca de geoprocessamento TerraLib.

O SPRING, que reflete um grande esforço da pesquisa nacional na área de sistemas computacionais para sensoriamento remoto, gratuito e disponível a qualquer pessoa para *download* (SPRING, 2012) é um sistema voltado para Sistemas de Informação Geográfica (SIG), com funções de processamento de imagens, análise espacial, consulta a bancos de dados espaciais e modelagem numérica de terreno. Ele é resultado de um projeto inteiramente nacional do INPE/DPI (Instituto Nacional de Pesquisas Espaciais/Divisão de Processamento de Imagens, em São José dos Campos, São Paulo) com a participação de diversos setores do Governo Federal. Por tais motivos, num primeiro momento desta tese houve a intenção de se

analisar o SPRING frente ao integrador. Ocorre que até a atual versão ele não apresenta classificadores que utilizem mais de três bandas (composição de bandas), o que inviabiliza a comparação com os demais sistemas e com o integrador (SPRING, 2012).

Assim sendo, os sistemas computacionais escolhidos para comparação com o integrador foram o IDRISI e o ENVI, segundo os seguintes critérios:

- Serem os mais utilizados pelos pesquisadores (comunidade científica) e por profissionais e empresas do ramo do sensoriamento remoto no Brasil (TEIXEIRA, 2004, 2008, 2010);
- Possuírem módulos ou funções de classificação não supervisionada de padrões em imagens multiespectrais; e
- Realizarem a classificação dos padrões pixel-a-pixel em imagens.

1.2.3 Análise espectral

A resposta espectral tem sido subutilizada ou, melhor dizendo, discriminada devido ao fato estático e tácito que esta é insuficiente para a interpretação de imagens, pois existem diferentes classes de cobertura e ocupação do solo que apresentam respostas espectrais semelhantes. Frente a tal pensamento em voga, apresentam-se os seguintes pontos:

- 1) Quanto à questão de insuficiência: em verdade, qualquer dado, por si só é insuficiente para explicar o todo, principalmente sendo este natural, tal qual preconizado pelo princípio sistêmico de Morin, Ciurana e Motta (2007);
- 2) Quanto à questão das respostas espectrais estas, pelo menos nos sistemas avaliados e nos diversos trabalhos pesquisados, não tem sido tratadas tal qual um especialista de imagens faz, o que pode trazer um incremento significativo à classificação de padrões multiespectrais, como se pretende demonstrar com a integração proposta; e
- 3) Se tal pensamento fosse fato consumado, não haveria necessidade de desenvolvimento ou estudos quanto aos sensores hiperespectrais.

Tal subutilização da análise espectral teve seu surgimento em uma época em que os sensores hiperespectrais ainda estavam sendo concebidos, formulados, e os multiespectrais não possuíam bandas acima da ordem das unidades. Nos tempos atuais, com a variedade existente e com aqueles a serem lançados, há que ser reformulada esta posição. Como exemplo de reformulação que se avizinha, cita-se que o sistema computacional eCognition

(criado em 1986 e atualmente um sistema vendido pela Trimble, USA), muito utilizado por usuários do mundo inteiro, conhecido por ser baseado estritamente em classificação de imagens por objetos, na sua versão mais atual, a de 2012, incluiu um módulo com de classificação pixel-a-pixel, que permite análises espectrais, pois verificou que esta classificação não pode ser inteiramente desprezada, acrescentando significativa qualidade no refinamento da classificação: tal fato foi relatado por um representante da firma em palestra assistida em setembro deste ano.

Por conta desta “discriminação”, está havendo uma lacuna de estudos relevantes quanto à análise espectral, principalmente no Brasil. Esta tese não pretende substituir ou provar que a classificação de imagens multiespectrais baseadas em análise espectral irá proporcionar resultados melhores que os de métodos que incorporem outros tipos de informação além da espectral, como forma, textura ou temporal. Pretende-se que este tipo de análise seja reavaliada, principalmente em virtude da cada vez mais frequente utilização e expansão dos sensores hiperespectrais, e que ela seja valorizada tanto quanto as demais análises.

Como, em essência, o imageamento capta uma amostragem da informação espectral de uma cena (LILLESAND; KIEFER, 1994), os registros digitais encerram a informação espectral discretizada do estado de cada um dos objetos da cena, no instante dessa captação.

Segundo Meneses e Netto (2001), Shaw e Burke (2003), Teixeira (2004) e Ponzoni e Shimabukuro (2009), o comportamento espectral de um objeto é variável devido à variáveis ambientais (temperatura, umidade, chuva, neve, vento, luz solar, estação do ano, dentre outros), fatores físicos intrínsecos (próprias estruturas dos objetos como composição, oxidação e envelhecimento), fatores físicos extrínsecos (como insolação, estresse, fadiga, cisalhamento, inundação, terremotos, furacões, etc.) e fatores antrópicos.

Assim, tal comportamento é extremamente mutável, tornando os sistemas comerciais existentes, calcados em curvas espectrais médias, em fusões padrão, imensamente limitados e tendentes ao erro. Logo, a utilização de um maior número de registros possível é imprescindível para a melhor caracterização dos objetos, conduzindo à necessidade do pleno conhecimento do conjunto de padrões espectrais de cada objeto, isto é, da assinatura espectral dos objetos desejados em uma cena, consideradas as interações entre as diversas bandas. Como o comportamento espectral de um objeto é representado pela sua assinatura espectral, e como este comportamento é mutável, conclui-se que um objeto poderá apresentar variadas assinaturas espectrais, apesar do objeto manifestar uma ínfima ou nenhuma variação intrínseca.

Desse modo, verifica-se o porquê dos algoritmos baseados, unicamente, no comportamento espectral (fundamentado em curvas de refletâncias médias) serem limitados e tendentes ao erro constante. Portanto, se afigura que o desejável é se obter algoritmos de classificação que utilizem diretamente os registros digitais (de várias ou de todas as bandas), de forma a possibilitarem o manejo com as assinaturas espectrais dos objetos, além de permitirem a contínua agregação do conhecimento sobre as variâncias espectrais admissíveis que são provocadas pelas variáveis ambientais. Por conseguinte, um objeto geográfico só poderá ser plenamente caracterizado e classificado, com razoável nível de certeza “quando da modelagem matemática completa das suas quantizações espectrais nas diversas bandas de resolução radiométrica no espaço amostral ao qual pertence” (TEIXEIRA, 2004, p. 26).

O trabalho de Shaw e Burke (2003) apresenta uma introdução a imagem espectral, sua evolução histórica, seus fundamentos e discorre sobre a sua utilização frente a aplicações de reconhecimento de alvos e de classificações em imagens. Este artigo foi motivado pelo início de disponibilização de dados advindos de sensores hiperespectrais e a falta de preparo na época (o que infelizmente persiste até hoje) da comunidade científica, dos usuários e das empresas quanto ao trabalho com estes tipos de dados. Os autores utilizam o termo assinatura espectral como “a correspondência única entre o material e sua refletância espectral” (SHAW; BURKE, 2003, p. 10). Tal fato se deve as dezenas de bandas dos sensores hiperespectrais que permitem o levantamento quase que completo da assinatura espectral de um determinado objeto geográfico, de forma que a necessidade de outros recursos como forma, textura, tamanho, dentre outros aspectos do reconhecimento visual, serão mais uma característica, mas não serão mais tão essenciais. Eles alertam para a variabilidade da refletância espectral dos objetos causada por erros de compensação do sensor, atmosféricos e ambientais, sendo que “as variações sazonais introduzem mudanças enormes no caráter espectral de uma cena” (SHAW; BURKE, 2003, p. 10), sendo que os objetos naturais apresentam maior variabilidade que aqueles que apresentam materiais resultantes de ações antrópicas. Os autores reconhecem que há muito ainda a ser pesquisado em relação aos métodos para a extração de informações de forma rápida de tal número de bandas (os métodos citados são baseados em redução do uso do número de bandas, tal qual realizado quando do surgimento do LANDSAT, pois os algoritmos e computadores não eram capazes de lidar com sete bandas, sendo necessária a redução para três bandas).

Schroeter e Gläßer (2011) utilizam imagens do LANDSAT-5 e 7 (todas as bandas), com o programa ENVI 4.1, para o estudo de poluição em lagos próximos a minas de extração de minérios na Alemanha, fazendo a comparação da assinatura espectral das imagens do satélite com os dados coletados *in situ*. A associação das assinaturas espectrais com os dados

coletados foi realizada com o conhecimento de especialista, que realizou um estudo de correlação das assinaturas com a poluição, de forma que a monitorização dos lagos pode ser realizada apenas através das imagens de satélite, comprovando a aplicabilidade e a praticidade do LANDSAT para monitoramento de poluição em lagos.

No trabalho de Lin e Imai (2011), apesar de não ser voltado especificamente para as imagens multiespectrais orbitais atuais, ele apresenta os sensores ajustáveis que proporcionam o ajuste da refletância estimada da cena, com características bem superiores aos sensores utilizados atualmente nos satélites de sensoriamento remoto: o trabalho aponta para um novo paradigma na imagem espectral que passará a ser reconfigurável, adaptando-se a cena, proporcionando a reconfiguração, por computação, da captura de imagens – este novo método de imageamento espectral apresenta desempenho e eficiência superiores aos atuais sistemas de imageamento espectral.

El-Saba, Alam e Sakla (2010) apresentam um estudo da importância do conhecimento e utilização efetiva dos sensores multiespectrais (MS) e hiperespectrais (HS) no reconhecimento de padrões em imagens advindas de sensoriamento remoto. Eles também valorizam a utilização de assinaturas espectrais quando relatam:

Com o processamento no domínio espectral, cada pixel tem um espectro correspondente que pode ser utilizado para identificar os materiais presentes em uma classe específica do solo. Assim, o processamento espacial explora a informação da geometria da forma, ao passo que o domínio espectral permite o processamento de um pixel de cada vez. Além disso, o processamento do domínio espacial requer resolução espacial muito elevada para identificar alvos através das respectivas formas, enquanto que o processamento do domínio espectral requer apenas um único pixel para a identificação, uma vez que a *assinatura espectral* é utilizada para identificar o objeto. As vantagens do processamento espectral foram evidentes nas aplicações iniciais de sensoriamento remoto que envolveram exploração mineral, classificação de cobertura do solo, caracterização da saúde de culturas. Nestas aplicações, a informação morfológica não é útil, pois os diversos materiais naturais de interesse não possuem formas pré-determinadas. O processamento espectral é mais adequado para aplicações em que a informação espectral é mais confiável do que a informação da forma, ou quando o tamanho do alvo é limitado a apenas alguns pixels. Por exemplo, na análise de veículos militares, a MSI / HSI não é afetada por tentativas de dissimulação e ilusão, uma vez que não depende da disposição espacial do objeto dentro da imagem (EL-SABA; ALAM; SAKLA, 2010, p. 3).

El-Saba, Alam e Sakla (2010) ressaltam que apesar do surgimento dos dados advindos de sensores hiperespectrais, que proporcionam uma indiscutível capacidade de melhor discriminar a variabilidade espectral dos objetos de uma imagem, os sensores multiespectrais podem fornecer a melhor solução atualmente, pois não possuem alta complexidade de dados, possuem um custo mais baixo, produzem conjuntos de dados menores e tem uma relação de sinal-ruído bem maior que os sensores HS. Além disso, devido a alta complexidade intrínseca

destes, simples extensões dos tradicionais algoritmos de reconhecimento de padrões dos sensores MS não proporcionam a extração adequada de todo o potencial presente nos dados dos sensores HS podem fornecer: há a necessidade premente de famílias de algoritmos específicos para os HS de forma a remover as informações espectrais redundantes ou desnecessárias enquanto que são preservadas os dados relativos aos alvos desejados. Os autores propõem a utilização de informação polarizada e de fusão de dados para a diminuição de falsos alarmes na classificação automática de padrões em imagens.

1.2.4 Pixel mistura

O pixel mistura ou mistura de classes (Figura 5) é a ocorrência de mais de uma classe em um pixel (também chamado de célula de resolução – *cell resolution*) da imagem. Tal fato ocorre principalmente em sensores com uma resolução espacial menor, como o LANDSAT (30 m) e o SPOT (20 e 10 m), onde o pixel pode apresentar “uma resposta espectral que não é característica de nenhuma das classes componentes” (CAIMI, 1993, p. 2), como, por exemplo, uma resposta espectral média das classes presentes.




Figura 5 - Representação de um pixel mistura em uma imagem LANDSAT (ALVES, 2004, p. 35).

A grande maioria dos algoritmos utilizados na classificação automática de padrões é restritiva, pois estes trabalham somente com o pixel em si, com cada pixel (elemento primordial) da imagem de forma independente dos pixels situados na sua vizinhança, o que acarreta “resultados estatisticamente significativos, mas espacialmente incoerentes” (ALVES,

2004, p. 34). Assim, tem-se a atribuição de um pixel a uma classe somente, tal qual o algoritmo clássico Maxver (Máxima Verossimilhança), muito utilizado em classificações, onde ocorre uma estimativa equivocada das áreas ocupadas pelas classes presentes na imagem analisada.

Logo, depreende-se que o pixel mistura está relacionado com os seguintes fatores:

- a) O tamanho do pixel de um sistema sensor *versus* o tamanho da classe que será analisada: quanto maior for a área da superfície terrestre que irá corresponder a um pixel somente no sistema, maior será a probabilidade de ocorrência de mais de uma classe; e
- b) o efeito das bordas das classes: “quando, em um pixel, ocorre o encontro entre duas ou mais classes” (CAIMI, 1993, p. 7) presentes no terreno.

Segundo Alves (2004, p. 35) “o pixel mistura apresenta como resposta espectral, a média de todos os materiais presentes dentro do pixel”, daí ocorrem os erros de classificação em imagens com baixa resolução espacial quando da utilização dos algoritmos tradicionais baseados na média dos valores espectrais dos pixels para a classificação de padrões: um pixel significa uma classe específica (lógica booleana). Foody (1997) concorda quando relata que as rotinas de classificação não se adequam para a modelagem de um ambiente natural, pois este não segue os padrões booleanos, possuindo gradações entre as classes, principalmente quando da ocorrência de transição de uma classe para a outra. Para a resolução deste problema, a classificação baseada em lógica difusa (*fuzzy*), com diferentes abordagens e metodologias, são apresentadas por Caimi (1993), Alves (2004), Campana (1992), Zhang e Kirby (1997) e Becerra e Bitencourt (2003), principalmente quando da classificação de áreas urbanas, local onde o pixel mistura mais aparece, subdividindo o pixel de forma possibilitar a classificação das diversas ocorrências presentes no pixel analisado: é atribuído ao pixel um grau de pertinência (de zero a um, dos números reais) que o correlaciona a cada classe, sendo zero correspondente a classe que não está presente no pixel até o valor de um, que corresponde a classe que “ocupa” totalmente (100%) o pixel em questão.

1.3 Inteligência Computacional (IC)

A Inteligência Computacional (IC) é um ramo da pesquisa humana com o objetivo principal de desenvolver técnicas, algoritmos ou dispositivos computacionais que emulem dinamicamente os processos humanos de memorização, obtenção, conceituação, adaptação, autoaperfeiçoamento, compreensão, criação, distinção, inferência, aprendizagem,

interpretação e aplicação, o que resulta em uma emulação do conhecimento humano. O real início de desenvolvimento desta área ocorreu com a publicação do artigo do matemático inglês Alan Turing, *Computing Machinery and Intelligence*, na década de 50 do século passado, passando a ter o respaldo de diversos cientistas, dentre eles Marvin Minsky, Walter Pitts, John McCarthy, Allen Newell e Warren McCulloch (BITTENCOURT, 1998).

Alan Turing propôs, em 1950, o Teste de Turing, onde pode ser determinado se uma máquina apresenta “inteligência” (emulação), consistindo em uma entrevista entre três entes: um interrogador humano, o computador que se deseja avaliar e um voluntário humano, sem que estes possam ser vistos pelo interrogador, se limitando à uma troca de mensagens. O computador poderá se utilizar de quaisquer artifícios (emulação de emoção, errar a resposta ou respostas, etc) de modo a emular o conhecimento humano, cabendo ao interrogador descobrir qual de seus entrevistados é o computador (ENGELBRECHT, 2007).

A IC se estabeleceu somente como uma ciência, isto é, com integrações e taxinomias próprias, com o advento do computador moderno, nos anos 60 do século XX, e, principalmente, com o surgimento do computador pessoal, na década de 70. Num primeiro momento, a IC visava unicamente a reprodução do pensamento humano. Com o passar do tempo, verificou-se que ela deveria modelar não somente o pensamento do homem, mas sim o seu conhecimento, que envolve diversos processos e fatores (SUMATHI; PANEERSELVAM, 2010). Em verdade, a IC passa por contínuas transformações à medida que as pesquisas acerca do cérebro e da psique humanas evoluem. Como estas pesquisas possuem características multidisciplinares e transdisciplinares, ocorrem, obviamente, variadas interpretações e vertentes que, geralmente, são conflitantes e contraditórias (ENGELBRECHT, 2007).

A tecnologia baseada em IC tornou possível a realização pelas máquinas de tarefas tediosas, complexas, altamente consumidoras de tempo, insalubres ou inseguras sem a presença constante do homem, proporcionando, assim, o aumento da eficiência através da interação com procedimentos automatizados.

Os ramos desta ciência são variados, como a Lógica Difusa (LD) ou Nebulosa (*fuzzy*, em inglês), as Redes Neurais Computacionais – RNC (ou Redes Neurais Artificiais – RNA), a Visão Computacional, os Sistemas Especialistas (SE), os Algoritmos Genéticos, a representação do Conhecimento e a Robótica. Nos últimos 10 anos, verifica-se o aparecimento do termo Inteligência Computacional (IC) como substituto do termo Inteligência Artificial (IA), bem como o de Redes Neurais Computacionais como substituto de Redes Neurais Artificiais, uma vez que o termo computacional é bem mais abrangente e

mais apropriado do que o termo artificial (ENGELBRECHT, 2007; SUMATHI; PANEERSELVAM, 2010).

1.3.1 Lógica difusa

A Lógica Difusa, Nebulosa ou *Fuzzy*, tem a capacidade de inferir conclusões e gerar respostas baseadas em informações vagas, ambíguas, imprecisas e qualitativamente incompletas, admitindo valores lógicos intermediários entre a falsidade e a verdade: uma premissa varia em grau de verdade (ou de falsidade) de 0 a 1, o que gera premissas parcialmente verdadeiras ou parcialmente falsas (FOODY, 1997). Logo, esta lógica permite o tratamento de expressões que envolvem grandezas descritas de forma não clara, como, por exemplo, quando se passa instruções para uma pessoa, que está aprendendo a dirigir, no caso de frear o carro quando da percepção do sinal vermelho de trânsito: deve-se dizer para acionar o freio quando estiver a 5 metros do sinal ou acionar os freios perto do sinal? A resposta óbvia é a segunda, pois a primeira implica numa instrução muito precisa para ser implementada. Isto ilustra o quanto a precisão pode ser bem inútil, enquanto as informações vagas e imprecisas podem ser interpretadas e realizadas a contento. A linguagem utilizada no dia-a-dia é um dos exemplos de como a incerteza pode ser utilizada e propagada (NASCIMENTO JR; YONEYAMA, 2000).

Um dos aspectos principais da lógica difusa, a capacidade de captar, com concisão e clareza, as nuances do pensamento humano sem a necessidade de enquadrá-lo, obrigatoriamente, em modelos determinísticos, que são extremamente incompatíveis com as incertezas presentes. Outro exemplo é quando se tem três reservatórios, como mostrado na Figura 6. Se for solicitado que sejam classificados quanto ao grau de preenchimento de água, utilizando as palavras CHEIO e VAZIO, ter-se-ia que em (A) o reservatório está cheio e o reservatório em (C) está vazio. Mas, e quanto ao reservatório em (B)? Ele está 50% vazio ou 50% cheio? Está meio cheio ou meio vazio? Na verdade as duas opções estão corretas. Na lógica clássica da teoria dos conjuntos, ter-se-ia que encaixar a classificação do reservatório no conjunto cheio ou no conjunto vazio, negando a possibilidade de coexistência das duas classificações por estas possuírem, qualitativamente, conceitos antagônicos (KOSKO, 1994).




Figura 6 - Reservatório preenchido com 100% de água (A); reservatório preenchido com 50% de água (B); e reservatório preenchido com 0% de água (C).

Na lógica difusa, ter-se-iam três afirmações ou regras (KOSKO, 1994):

- a) O reservatório em (A) pertence ao conjunto VAZIO com grau de 0% e pertence ao conjunto CHEIO com grau de 100%;
- b) O reservatório em (B) pertence ao conjunto VAZIO com grau de 50% e pertence ao conjunto CHEIO com grau de 50%; e
- c) O reservatório em (C) pertence ao conjunto VAZIO com grau de 100% e pertence ao conjunto CHEIO com grau de 0%.

Logo, verifica-se que um objeto pode pertencer a uma ou mais classes, de acordo com um grau de pertinência específico, que será esmiuçado por um especialista naquele objeto, através de um conjunto de regras.

Em 1965, Lotif Zadeh na Universidade da Califórnia, em Berkeley, propôs os conjuntos difusos: uma generalização da teoria dos conjuntos clássica, como uma forma matemática de representação da incerteza, que expressa o que ocorre diariamente no cotidiano do ser humano; que compreende, assimila, utiliza e se expressa constantemente através de dados difusos, regras vagas e informações imprecisas. Esta lógica fornece subsídios que permite aos modelos computacionais serem capazes de representar, reconhecer, manipular, interpretar e utilizar tanto incertezas nebulosas, quanto estatísticas (FOODY, 1997).

Em verdade, as bases para a lógica difusa foram lançadas em 1923 por Bertrand Arthur William Russell, um filósofo e lógico inglês, no seu artigo *Vagueness*. Russel é reconhecido por seus trabalhos em lógica-matemática e em filosofia analítica, e considerado um dos fundadores do logicismo, que é uma concepção onde a matemática, ou parte dela, pode ser reduzida à lógica. Os sistemas que utilizam esta lógica têm a habilidade de raciocinar de forma semelhante à dos humanos, já que trabalham com modelos matemáticos dedicados ao tratamento da incerteza, o que possibilita uma vasta aplicabilidade, como, por exemplo, em áreas de controle (de processos – tráfego, freios, lavagem, temperatura, etc.), de reconhecimento (assinaturas, impressões digitais, voz, imagem), de sistemas de tratamento de

água, de estabilização de imagem de câmeras e filmadoras, e de tomada de decisão (AGUIAR; JÚNIOR, 1999).

O método de inferência *fuzzy* de Mamdani é o mais utilizado dentre os métodos de lógica difusa existentes. Ele foi proposto por Ebrahim Mamdani em 1975, após ler a proposta de Zadeh, para o controle de uma máquina de vapor e caldeira através da síntese de um conjunto de regras linguísticas de controle com base nos experientes operadores desta máquina. Este método utiliza modelos linguísticos baseados em coleções de regras SE-ENTÃO para representar o conhecimento, com os antecedentes e os consequentes das regras expressos por valores difusos, obtendo-se assim um encadeamento difuso de ações, que resulta em um comportamento do sistema bem próximo ao natural, ao do humano (MAMDANI, 1975).

A lógica difusa é muito utilizada na classificação de padrões em imagens multiespectrais como no trabalho de Console e Mouchot (1996), que pesquisaram técnicas de lógica difusa na classificação de áreas urbanas em imagens multiespectrais. Os testes indicaram que a aplicação da lógica difusa em imagens do LANDSAT-5 é a mais adequada para classificações de padrões em áreas urbanas (áreas com alta heterogeneidade de padrões) frente aos métodos convencionais, onde o pixel classificado é atribuído à classe cujas características espectrais sejam as mais próximas, desconsiderando a possibilidade de assinaturas espectrais mistas: a lógica difusa se utiliza das funções de pertinência para a classificação dos pixels com base em uma grade de similaridade, de mistura de padrões de assinatura espectral. Foram observadas seis classes (área cultivada, pomar, floresta, cobertura gramínea, área sem vegetação e área urbana) na imagem, com a escolha de 103 conjuntos de treinamento. Apesar da área testada apresentar topografia acidentada, os índices de exatidão global foram de 0,75 para o classificador difuso frente aos índices 0,29 e 0,23 para os métodos clássicos de máxima verossimilhança (Maxver) e de distância mínima, respectivamente, sendo estes últimos indicadores de resultado bem inferior ao alcançado pelo classificador difuso. Ressalta-se que não foi mencionada se houve a ajuda de especialista em imagem nem a quantidade de bandas utilizadas do LANDSAT-5, depreendendo-se, então, que houve, pelo menos, a utilização de três bandas, uma composição que é característica básica para a visualização de padrões por analistas em imagens.

Utilizando também imagens LANDSAT-5 e também comparando os resultados encontrados com o classificador Maxver, Moretti *et al.* (2011) aplicou a lógica difusa na classificação da APA (Área de Proteção Ambiental) Fernão Dias para três tipos de cobertura Florestal (floresta ombrófila densa e mista e floresta semidecidual). O Maxver, algoritmo de classificação supervisionada, presente em variados programas voltados para o SR, realiza a

ponderação das distâncias médias a partir de parâmetros estatísticos que serão calculados com base nos pixels selecionados para os conjuntos de treinamento, gerando a necessidade de se estipular tais conjuntos com grande número de pixels (com mais de cem) de forma a se obter inferência estatística mínima, como alertado em Crósta (1992). Foi utilizado o sistema ENVI (sem informação da versão utilizada) para a classificação do Maxver, com a utilização de seis bandas (1, 2, 3, 4, 5 e 6). Ressalta-se que tal qual Teixeira (2004), estes autores se utilizaram de uma quarta classe, além das três em análise, denominando-a de OUTROS para aquelas presentes na imagem, mas não interessantes ao estudo. Utilizando-se o sistema IDRISI, com a coleta de conjuntos de treinamento através da função MakeSIG, a lógica difusa foi implementada através de função *Fuzzclass*, com a "defuzificação" pela mínima distância euclidiana, com o mesmo número de bandas utilizadas no ENVI. A comparação destes dois classificadores indicou índices Kappa de 0,9 para a Maxver frente ao índice Kappa de 0,91 para a lógica difusa. Apesar de resultados tão próximos, os autores alertam que a classificação difusa apresentou melhor classificação quanto as áreas de transição entre as três classes. Ressalta-se que o resultado foi próximo devido a utilização de padrões estatísticos semelhantes utilizados pelo Maxver e pela *Fuzzclass*, inerentes aos algoritmos utilizados por todos os programas comerciais: haveria diferença maior se fossem utilizadas inferências estatísticas próprias, como as de uma especialista em imagens.

Em relação a classificação de áreas impermeáveis em bacia hidrográfica (Arroio Dilúvio, em Porto Alegre), o trabalho de Alves (2004), utilizando imagens do LANDSAT-5 e 7, com as bandas 1 a 5 e 7, e com os sistemas IDRISI 32 e ENVI, versão 3.6, apresenta a utilização da lógica difusa, através da função *Fuzclass* (do IDRISI), para comparação com a classificação Maxver (do ENVI) em duas áreas-teste, situadas na região metropolitana de Porto Alegre, para quatro classes (água, vegetação, solo exposto e urbano). A lógica difusa alcançou indica Kappa médio de 91%, enquanto que a Maxver alcançou 67%. A diferença foi explicada devido a forte presença de área urbana nas áreas de teste, o que leva a lógica difusa a apresentar melhores resultados que classificadores rígidos ou booleanos como o Maxver.

Caldas e Guerra (2010) aplicam uma classificação não supervisionada difusa C-MEANS, com inferência Mamdani, em imagem do LANDSAT-5 (utilização de apenas duas bandas) para a detecção de três classes – água, vegetação e savana – em região no Pará com resultado bem próximo ao obtido por especialista em imagem, que realizou uma classificação prévia da área para a determinação dos conjuntos de treinamento, com a seguinte ressalva: a lógica difusa apresentou dificuldades na classificação de sombras na imagem, mas ocorre que o classificador não foi treinado para este tipo de classe.

O trabalho de Prado e Galo (2009), em uma área do estado de São Paulo, realizou comparação entre o Maxver, lógica difusa pela distância média e lógica difusa relativa bayesiana em uma imagem do LANDSAT-7 (bandas 1 a 5 e 7), com o programa IDRISI, versão ANDES, para oito classes (mata, cultura agrícola, corpo d'água, área urbana, solo exposto, pastagem, várzea, mata em regeneração). Especialista em imagem realizou a indicação dos dados para a formação dos conjuntos de treinamento de cada classe de interesse. As classes cultura agrícola e solo exposto foram as com menor índice na classificação difusa relativa bayesiana; várzea e mata foram as classes com menor índice na classificação difusa bayesiana. As classificações Maxver e lógica difusa bayesiana apresentaram resultados bem similares (concordância especial alta) devido a ambos serem fundamentados no Teorema de Bayes. A classificação difusa pela distância média obteve resultados significativos frente a Maxver, principalmente nas classes cultura agrícola e pastagem.

Teixeira (2004) utiliza as bandas 1 a 5 e 7 do LANDSAT-7 para a classificação de quatro classes em duas áreas no Estado do Rio de Janeiro, através da utilização de lógica difusa implementada em MATLAB, com auxílio de especialista em imagens para a implementação das regras. O algoritmo utilizado foi o ANFIS com o método de inferência Mamdani, função de pertinência trapezoidal, com “defuzzificação” pelo menor dos máximos, que obteve um nível de acerto médio das classes de 79% e 76% para cada uma das áreas analisadas, sendo que a classe Manguezal foi a que obteve o menor índice de classificação (50% e 70%, respectivamente). Sem a contabilização desta classe (considerada a de pior classificação, pois é constituída de ambientes secos e úmidos), os acertos tiveram índices médios de 85% e 82% considerados muito bons para uma classificação rápida de uma área. Houve comparação com os resultados encontrados pelos programas IDRISI e ENVI, que resultados inferiores aos apresentados pela implementação em MATLAB.

Foody (1997), Noguchi (2004), Shani (2006), Zhao, Chen e Stein (2008), Salman e Seno (2011) são indicações de outros trabalhos que apresentam resultados eficientes na classificação de imagens multiespectrais com lógica difusa frente aos métodos clássicos.

1.3.2 Rede Neural Computacional (RNC)

Na Inglaterra, em meados do século XVIII, a era agrícola começou a ser suplantada pela máquina a vapor devido a uma combinação de diversos fatores políticos, econômicos, sociais e científicos (por exemplo, o liberalismo econômico, a acumulação de capital e,

principalmente, por uma série de invenções). Iniciava-se a Revolução Industrial, como o próprio nome diz, que revolucionou a sociedade humana em todos os níveis através de um conjunto de mudanças tecnológicas que geraram um grande impacto no processo produtivo. A partir do século XIX houve uma expansão dessa nova ordem para o restante do mundo, que, com o passar do tempo, gerou o estabelecimento de uma nova relação entre capital e trabalho e de novas relações entre os países (estabelecimento do capitalismo como o sistema econômico vigente); o que resultou, na segunda metade do séc. XX, no fenômeno da cultura de massa (globalização).

Devido a todos estes fatos, houve uma evolução muito rápida das máquinas, gerando no homem um anseio pela criação de uma máquina que pudesse operar independentemente do controle humano: uma máquina que fosse independente, de acordo com seu próprio aprendizado e com a capacidade de interagir com ambientes incertos, desconhecidos e inesperados – uma máquina inteligente, autônoma, ou cognitiva. Tais máquinas teriam maior capacidade de aprender tarefas de alto nível cognitivo que, com constante adaptação, realizariam suas tarefas com maior eficiência, de modo gradativo, como um ser humano, mesmo em condições de ambiente imprevisíveis. Portanto elas seriam muito úteis onde a iteração humana é perigosa, tediosa ou impossível (HAYKIN, 2001).

As Redes Neurais Computacionais (RNC) consistem em técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes (normalmente, o humano) e que adquirem conhecimento através da experiência. Assim, elas são, verdadeiramente, uma emulação e não uma simulação, visto que uma grande RNC pode ter centenas ou milhares de unidades de processamento, enquanto que o cérebro de um mamífero pode ter muitos bilhões de neurônios; os tempos de processamento são diferentes; e os processos realizados são extremamente contrastados (ENGELBRECHT, 2007).




Figura 7 - Principais componentes de um neurônio humano (GSI, 1999).

O sistema nervoso humano é formado por um conjunto extremamente complexo de neurônios, onde a comunicação é realizada através de impulsos elétricos, com um papel essencial na determinação do funcionamento, comportamento e do raciocínio do ser humano. Os principais componentes dos neurônios (Figura 7) são os dendritos (que recebem os estímulos transmitidos pelos outros neurônios), o corpo de neurônio ou *somma* (responsável por coletar e combinar informações vindas de outros neurônios) e o axônio (fibra tubular, que pode alcançar até alguns metros, responsável pela transmissão dos estímulos para outras células). As redes neurais (naturais), ao contrário das RNC, não transmitem sinais negativos, sendo sua ativação medida pela frequência com que emite pulsos contínuos e positivos, não são uniformes como as RNC e apresentam uniformidade apenas em alguns pontos do organismo (GSI, 1999).

Fazendo-se uma analogia, um grafo direcionado é um objeto geométrico com um conjunto de pontos, chamados nós, ao longo de um conjunto de segmentos de linhas direcionadas entre eles, enquanto que uma RNC é uma estrutura de processamento de dados, distribuída paralelamente na forma de um grafo direcionado, com algumas restrições e definições próprias. Os nós deste grafo são chamados de elementos de processamento, sendo suas arestas as conexões, que são “caminhos” de condução de sinais em uma única direção, de forma que seus elementos de processamento podem receber qualquer número de conexões de entrada. As conexões podem possuir memória local e qualquer número de conexões de saída, desde que os sinais nestas conexões sejam os mesmos. Portanto, tais elementos têm, na verdade, uma única conexão de saída, que pode se dividir em cópias para formar múltiplas conexões, sendo que todos carregam o mesmo sinal. A função de transferência opera continuamente ou esporadicamente (GSI, 1999; SUMATHI; PANEERSELVAM, 2010).

De forma geral, a operação de uma célula da RNC se resume em: sinais são apresentados à entrada; cada sinal da entrada é multiplicado por um peso, que indica sua influência na saída da unidade; é realizada uma média ponderada dos sinais, que produz um nível de atividade; e se este nível excede um limite (*threshold*) a unidade produz uma saída (FU, 1994), como pode ser visto na Figura 8.




Figura 8 - Esquema de um neurônio computacional (GSI, 1999).

A RNC é um sistema de neurônios ligados por conexões sinápticas e dividido em neurônios de entrada (recebem os estímulos do meio externo), neurônios internos ou ocultos (que realizam o processamento) e neurônios de saída (que se comunicam com o exterior). Em outras palavras, pode-se dizer que uma RNC é composta por várias unidades de processamento, de funcionamento simples, conectadas por canais de comunicação associados a determinados pesos. Estas unidades realizam operações apenas sobre os dados (entradas) recebidos. Logo, o comportamento inteligente de uma RNC vem das interações entre as unidades de processamento da rede (FU, 1994; SUMATHI; PANEERSELVAM, 2010).

Os modelos de RNC possuem regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados, de forma que elas “aprendem” através de exemplos, sendo o processo de treinamento realizado a partir de casos reais conhecidos. Assim, a rede neural é capaz de extrair regras básicas a partir de dados reais, diferindo da computação programada, onde é necessário um conjunto de regras rígidas pré-fixadas. As arquiteturas das RNC são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior (HAYKIN, 2001).

Vieira (1993) faz uma análise criteriosa das técnicas de classificação não supervisionada em imagens do satélite LANDSAT-5 (bandas 1 a 5 e 7), comparando os métodos clássicos – Maxver, Mahalanobis, Distância Mínima e Paralelepípedo – com RNC Backpropagation, para as classes água, floresta, desflorestamento e elemento não identificado (desconhecido). Foi constatado que a RNC proporcionou incrementos significativos na qualidade dos resultados, apresentou índice de acerto 11% maior que a Maxver, que foi o melhor classificador, dentre os métodos clássicos. O autor ressalta a importância da seleção dos dados dos conjuntos de treinamento da rede, o que deve ser extensivo para qualquer tipo de RNC, pois estes tem que conter todas as informações relevantes sobre o comportamento das classes analisadas: sejam as mais óbvias e características, como também as condições de contorno (pontos ou situações onde há mudança de comportamento das classes).

Os Mapas Auto-Organizáveis (SOM – *Self-Organizing Maps*) ou Mapas de Características Auto-Organizáveis (SOFM – *Self-Organizing Feature Maps*) de Kohonen é uma rede neural computacional de aprendizagem competitiva organizada, basicamente, em duas camadas. Este método pertence à classe de RNC não supervisionada, as quais se baseiam no processo de aprendizagem competitiva, no qual somente um neurônio de saída ou um grupo local de neurônios fornece uma resposta ativa a um sinal de entrada (KOHONEN, 1984, 1997). Este tipo de rede permite a detecção de graus de similaridade entre os dados de entrada, o que a torna extremamente útil no processamento de imagens multiespectrais.

Arias *et al.* (2009) apresentam uma classificação de imagem do LANDSAT baseada em mapas auto-organizáveis (SOM) pois este método permite a possibilidade de aprendizado não supervisionado e possui a capacidade de trabalhar com todas as bandas do sensor. Foi utilizada a classificação de imagem do LANDSAT-7, com três bandas, de duas áreas teste no Equador, com método de treinamento não supervisionado. Foram obtidos índices Kappa de 64% e de 82%, que são bons, mas seriam melhores se a coleta dos conjuntos de treinamento tivesse sido realizada por especialista em imagens.

O trabalho de Gutiérrez (2003) apresenta uma rede SOM (grade retangular 5x3, implementada no programa HidroSIG) para a classificação de oito tipos de coberturas vegetais em imagens do LANDSAT-7 na Colômbia, que foi comparada com classificação ISODATA realizada no programa *Image Analyst*. Foram utilizadas somente as bandas 3, 4 e 5 do sensor. A classificação ISODATA não conseguiu diferenciar claramente qualquer uma das coberturas vegetais: a representação foi menor que 50%. A SOM também não obteve um índice tão alto (pouco acima de 50%), mas o autor indica que tal ocorreu devido a redução das bandas de entrada de seis bandas para somente três bandas, o que causou uma caracterização incompleta das classes de cobertura vegetal.

O trabalho de Villman e Merènyi (2000) apresenta a classificação de imagens do satélite LANDSAT-5 (bandas 1 a 5 e 7) e do AVIRIS (utilizou 194 bandas das 224 originais), em uma mesma área de Nevada (USA), para estudo de 23 classes geológicas através da rede GSOM, um incremento das redes SOM de Kohonen, com resultados de índice Kappa de 95% para o LANDSAT e 90% para o AVIRIS. Em um trabalho mais recente, Merènyi e Villman (2002) apresenta a rede SOM (através do programa *NeuralWares NeuralWorks Professional II/Plus*) aplicada a imagens hiperespectrais do satélite AVIRIS de uma área de Nevada, USA, para oito classes geológicas. Houve a redução das 224 bandas para conjuntos de 194, 30 e 13 bandas, todas com significação para as classes em estudo, de forma a comparar os resultados com métodos clássicos como Maxver, Distância Mínima Euclidiana (DME) e Mahalonobis. Para 194 bandas a SOM alcançou 90% de índice Kappa, ficando os demais métodos abaixo de

82%. Para 30 bandas a SOM alcançou 74% e os demais abaixo de 72%. Para 13 bandas a SOM obteve 76% e os demais ficaram abaixo de 72%. Foi observado que o MaxVer e a DME obtiveram índices bem próximos.

O trabalho de Gonçalves *et al.* (2008) utiliza de uma rede SOM com os dados de vizinhança dos pixels vizinhos resultante do processo de coleta dos conjuntos de treinamento automatizada (sem o concurso de especialista em imagens). As bandas 3, 4 e 5 do LANDSAT-5 foram utilizadas para classificação de quatro grandes classes (área urbana, vegetação e dois padrões de água – Rio Negro e Rio Solimões) e as amostras (conjuntos de treinamento) foram coletadas automaticamente: diferentemente dos outros trabalhos analisados, esta são quadradas com 5x5 pixels – as janelas de pixels – com um total de 2500 amostras. Uma topologia de grade retangular 10x10 foi utilizada. Os resultados foram comparados com classificação K-MEANS, sendo o índice Kappa da SOM igual a 0,96. Os autores também computaram o tempo despendido nas classificações ficando a Som com 155 s e o K-MEANS com 93 s, que apesar de ser mais rápido, obteve classificação inferior ao SOM.

Gonçalves, Netto e Júnior (1996) implementaram uma variante do método SOM em imagem do LANDSAT (com as bandas 4, 5 e 7) para análise de cinco classes de cobertura terrestre (solo nu, água, solo úmido, pastagem e plantação de cana), incluindo uma sexta classe com os pixels não classificados (na cor preta) com nível de acerto bem próximo ao obtido por especialista em imagem, que realizou uma classificação prévia da área para a determinação dos conjuntos de treinamento.

O trabalho de Freitas *et al.* (2009) realizou classificação baseada em rede SOM em imagens do LANSAT-5 (bandas 1 a 5 e 7) para estudo de áreas de expansão de cana-de-açúcar no Estado de São Paulo. Um especialista em imagens estipulou as classes de interesse como sendo área agrícola, pastagem, citrus, vegetação natural e cana-de-açúcar, posteriormente extraindo os conjuntos de treinamento da imagem. Foi utilizada a topologia de grade hexagonal, função de vizinhança gaussiana e algoritmo de treinamento em lote. A classe cana-de-açúcar foi a que obteve maior acerto, se destacando das demais, caracterizando que a rede SOM é uma boa ferramenta para a interpretação de resultados, pois fornece uma visão integrada do conjunto de dados permitindo uma melhor análise.

Silva, Monteiro e Medeiros (2002) utilizou a rede SOM em imagens LANDSAT com três bandas já classificadas com os temas declividade, geologia e uso da terra para a geração de um mapa de risco com quatro classes (risco muito alto, médio, baixo e alto), com conjuntos de treinamento indicados por especialista, com índice de acerto nas amostras de 95%.

Silva (2003) utiliza somente as características espectrais das imagens LANDSAT-5 (bandas 1 a 5 e 7) para classificá-las através de três tipos de RNC não supervisionadas –

Mapas Auto-Organizáveis (SOM), *Fuzzy-Art* e ART-2. A fim de realizar classificação automática, o autor utiliza operadores genéticos para os parâmetros livres dos classificadores neurais utilizados. Para a classificação de quatro classes de cobertura (vegetação, água, área urbana e cerrado) a rede SOM alcançou resultados médios de acerto superior em 15% em relação às outras duas redes analisadas.

O trabalho de Peschel (2002) aplica *Adaptive Neuro-Fuzzy Inference System* (ANFIS) para a classificação de imagens LANDSAT-5. Para o mesmo satélite, Nishida (1998) utiliza uma RNC com função de base radial para classificação. Weber (2005) apresenta um trabalho onde integra dados espectrais e indicadores meteorológicos através de uma RNC *Multilayer Perceptron* (MLP) para estimativa de safras em imagens LANDSAT-5 com incremento muito significativo da classificação resultante frente aos métodos clássicos Maxver e ISODATA.

2 MATERIAIS E MÉTODOS

Apresenta as etapas vinculadas à cena escolhida para análise, definição e caracterização das classes em estudo, interpretação visual, sistemas computacionais comerciais e funções selecionadas, integração proposta, além da implementação e teste do integrador.

2.1 Cena escolhida para análise

2.1.1 Parâmetros

A primeira opção para utilização de cena multiespectral foi a do satélite CBERS (*China-Brazil Earth Resources Satellite* ou Satélite Sino-Brasileiro de Recursos Terrestres), que advém de uma parceria inédita entre Brasil e China no setor técnico-científico espacial, o que permitiu ao Brasil ingressar no seleto grupo de países detentores de tecnologia de Sensoriamento Remoto, através de uma poderosa ferramenta para monitorar nosso imenso território: o satélite de coleta de dados (CBERS, 2006). O INPE também está disponibilizando as cenas do CBERS de forma gratuita, mediante cadastro e aceite dos termos de utilização (INPE, 2011). Ocorre que as imagens do CBERS-2 não puderam ser utilizadas nesta tese, pois possuíam erros em radiometria (nos registros digitais), o que prejudicaria o teste da integração proposta. O CBERS-2B, que foi lançado em setembro de 2007, apresentava poucas cenas e ainda estava na fase de ajustes do sistema quando da definição final do sensor a ser utilizado em meados de 2008.

A missão do programa LANDSAT é a de prover aquisições repetitivas de dados multiespectrais da média resolução (até a época do último satélite da constelação, o LANDSAT-7, em 1999) da superfície terrestre, de modo a permitir a realização de análises mais integradas dos diversos objetos e feições geográficas, bem como os temas a ele relacionados (NASA, 2012). Atualmente este é o único sistema capaz de prover a comparação dos dados atuais de uma determinada área com dados antigos, devido ao seu funcionamento desde 1972. Assim, o programa LANDSAT possui o mais longo registro histórico da superfície terrestre.

O satélite LANDSAT-7 foi descartado, pois além de também possuir problemas em radiometria, o que inviabilizaria o teste da integração proposta, não está em funcionamento desde meados de 2003, não havendo cenas de épocas mais próximas as atuais.

Portando, foi escolhido o satélite LANDSAT-5, lançado em março de 1984, devido aos seguintes fatores:

- a) Em termos de temporalidade de imagens, este é o único satélite que permite uma série temporal de mais de 25 anos, possuindo ainda compatibilidade de dados com as missões 4 e 7, o que aumenta ainda mais a série histórica;
- b) Possuir uma resolução espacial média (30m), abarcando a maioria dos padrões de objetos geográficos das classes escolhidas como de interesse para classificações de cobertura da terra de uma região;
- c) Possuir um dos preços mais acessíveis dentre os sistemas orbitais multiespectrais atuais (o INPE disponibiliza gratuitamente as imagens (INPE, 2011), mas estas também podem ser adquiridas comercialmente com um maior nível de correção do que o oferecido pelo referido instituto);
- d) Oferecer uma boa diversidade de bandas (sete, ao todo), permitindo uma análise integral válida das classes desejadas; e
- e) Garantia de precisão radiométrica absoluta de +/-5%.

Todos estes fatores representam um enorme e único acervo de dados da superfície terrestre, propiciando a utilização, a pesquisa e o aperfeiçoamento de algoritmos que utilizam dados multiespectrais na área de Sensoriamento Remoto.

A cena do LANDSAT-5 contém nível 2 de correção (formato GEOTIFF – *Geographic Tagged Image File Format*, derivado do formato TIFF), permitindo a associação de dados cartográficos aos pixels da imagem, indicando que há tanto uma geometria, quanto uma radiometria razoáveis para a análise de padrões a que se propõe a integração trabalhada. Portanto, não houve a necessidade de se utilizar técnicas de correção de distorções, que, em si, já implicariam na realização de outros trabalhos e pesquisas específicos. Cada banda da cena possui profundidade, ou quantização de pixel, de 8 bits, admitindo, com isso, 256 níveis de cinza, o que permite uma boa discriminação para a geração da assinatura espectral das classes do integrador.

Para se obter um melhor resultado em radiometria, optou-se por não utilizar a banda termal 6 do LANDSAT-5 por esta possuir uma resolução muito menor que as demais – 120m frente as demais de 30m: a tentativa de ajuste para uma melhor resolução da banda 6 não

representaria um ganho significativo em radiometria e alteraria significativamente o resultado da classificação das classes de interesse.

A referência espacial ou geográfica (também conhecida por registro ou por georreferenciamento) é uma transformação que vincula a grade de pixels da imagem (uma matriz de pixels, composta por linhas e colunas) com a grade de coordenadas correspondente no terreno. Tal transformação não é uma preocupação da integração proposta, pois tal referência não acrescenta nenhum valor à classificação de padrões de uma imagem orbital. Em verdade, os algoritmos comumente utilizados para o referenciamento espacial de uma área realizam reamostragem dos pixels da imagem, o que causa alterações significativas dos níveis de quantização destes pixels, situação que deve ser evitada a qualquer preço antes da classificação de padrões. Esta referência pode e deve ser realizada após a classificação da imagem.

A escolha da cena da área-teste baseou-se, primordialmente, na região sudeste, mais precisamente no Estado do Rio de Janeiro e mais próxima possível da cidade do Rio de Janeiro, no caso de haver necessidade de ida a campo para corroboração da verdade terrestre, além de ser uma área de grande conhecimento da especialista em imagem.

A cena escolhida para análise foi a da órbita/ponto 217/76, que está contida completamente dentro do Estado do Rio de Janeiro, como pode ser observado na Figura 9 (programa *Google earth* utilizado para visualização da área, com realce da cena escolhida para análise em vermelho), a qual permite uma visão geral do posicionamento das cenas do LANDSAT-5 no espaço geográfico. A cena foi adquirida pelo satélite em 04 de junho de 2009, com todas as sete bandas presentes e com cobertura total de nuvens inferior a 10%, adquirida via Internet (INPE, 2011).

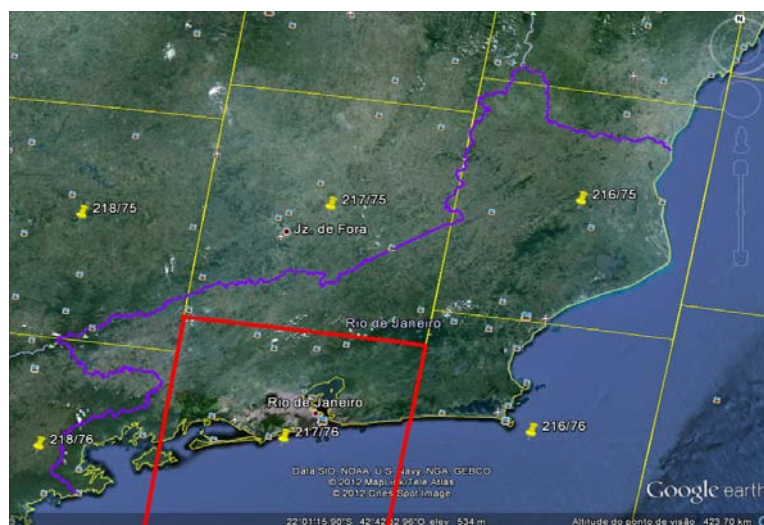


Figura 9 - Grade do satélite LANDSAT sobre parte da região sudeste do Brasil, com realce da órbita/cena selecionada em vermelho (modificada de GOOGLE EARTH, 2012).

2.1.2 Localização e caracterização da área-teste

A Figura 10 apresenta a área-teste para o teste da integração proposta, com os dados e a cena escolhida, tal qual apresentados na página do INPE (2011), disponível para *download*, mediante cadastro prévio do usuário.

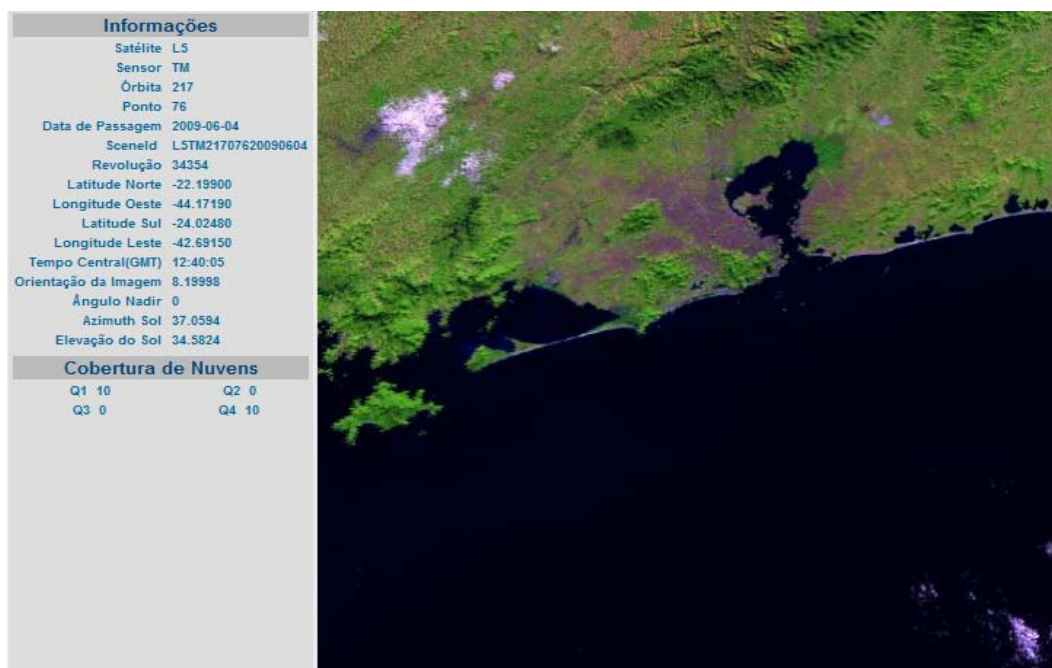


Figura 10 - Informações da cena 217/76 escolhida (parcial INPE, 2011).

A área-teste está situada na região centro-sul do Estado do Rio de Janeiro, compreendendo, aproximadamente, um terço do estado (além de uma diminuta parte do Estado de São Paulo), sendo 31 municípios abrangidos com cobertura total de seus territórios (Rio de Janeiro, Nilópolis, Niterói, Belford Roxo, Mesquita, Nova Iguaçu, Seropédica, Itaguaí, Barra do Piraí, Rio Claro, Paracambi, Mangaratiba, Queimados, Tanguá, Magé, Duque de Caxias, São Gonçalo, Itaboraí, Marica, Saquarema, Rio Bonito, Guapimirim, São João de Meriti, Japeri, Seropédica, Queimados, Miguel Pereira, Pinheiral, Volta Redonda, Mendes e Eng. Paulo de Frontin). Os municípios de Valença, Barra Mansa, Paraíba do Sul, Petrópolis, Araruama, Cachoeiras de Macacu, Paty do Alferes, Silva Jardim, Teresópolis, Angra dos Reis, Quatis e Vassouras são aqueles com cobertura parcial de seus territórios. Destaca-se ao sul a Ilha Grande (CIDE, 2009).

A seguir será apresentado um resumo das características físicas da região da cena utilizada – baseada em Muehe e Valentini (2009), CIDE (2009) e CPRM (2006) – referentes ao Estado do Rio de Janeiro.

Em termos geomorfológicos, o relevo da cena possui duas unidades representativas: a baixada (com terras com até 200m de altitude) e o planalto (com altitudes maiores de 200m). Além disso, possui estruturas geológicas vulcânicas (vulcão de Chaminé Lamego e de Nova Iguaçu) e duas grandes bacias hidrográficas (a da Guanabara e a da Baía de Sepetiba) (INEA, 2012).

A área de baixada é conhecida como Baixada Fluminense, que segue todo o litoral, ocupando quase metade da superfície de todo o estado. Da área da cidade do Rio de Janeiro até a região de Cabo Frio, esta baixada é predominante, dividindo-se em região de praias e cordões arenosos (extremo sul do Estado – Parati até a Ilha de Itacuruçá) e em região de restingas e lagunas (entre a Ilha de Itacuruçá e Arraial do Cabo).

A região de planalto é representada por três maciços na área perimetral da cidade do Rio de Janeiro, – o da Tijuca e o da Pedra Branca, com altitudes superiores a mil metros ambos, e o Gericinó-Mendanha – e no interior do estado pela Serra do Mar (também chamada de Serra dos Órgãos ou Serra das Araras) e pela serra da Mantiqueira, localizada na porção noroeste do estado (INEA, 2012).

O clima da região de baixada é predominantemente tropical semi-úmido, com chuvas abundantes, principalmente no verão e inverno (1.250mm/ano), com temperatura média de 25°C. Na região limítrofe entre a baixada e o planalto, o clima é o tropical de altitude. Já na região serrana, com o mesmo clima tropical de altitude, as médias são de 16°C e as chuvas são bem abundantes (2.200mm/ano).

A Mata Atlântica, um dos ecossistemas de floresta tropical mais ameaçado do mundo, está representada, nesta região, nas duas maiores florestas urbanas do mundo: a Floresta da Tijuca e a do Maciço da Pedra Branca. A vegetação remanescente da Mata Atlântica recobre restritas porções, como os topos de serras e encostas. Existem ainda as florestas ombrófilas nas Serra do Mar e da Mantiqueira; os manguezais, restingas, brejos e praias no litoral; os campos de altitude no Maciço de Itatiaia; e os campos de planície no delta do Paraíba do Sul.

2.1.3 Recortes 1A, 1B e 1C

Esta cena foi recortada em três imagens, todas dentro do Estado do Rio de Janeiro, a saber: recorte 1A – Guaratiba, recorte 1B – Mangaratiba e recorte 1C – Magé (Figura 11). Estas serão as utilizadas para classificação pela especialista em imagem, pelo integrador e pelos programas IDRISI e ENVI. O programa IDRISI Taiga foi utilizado para a visualização

da cena, o realce do contraste da cena, a composição de bandas e os recortes. O realce e a composição de bandas, realizado com as indicações da especialista em imagem, será explicitado melhor no item 2.2.1.

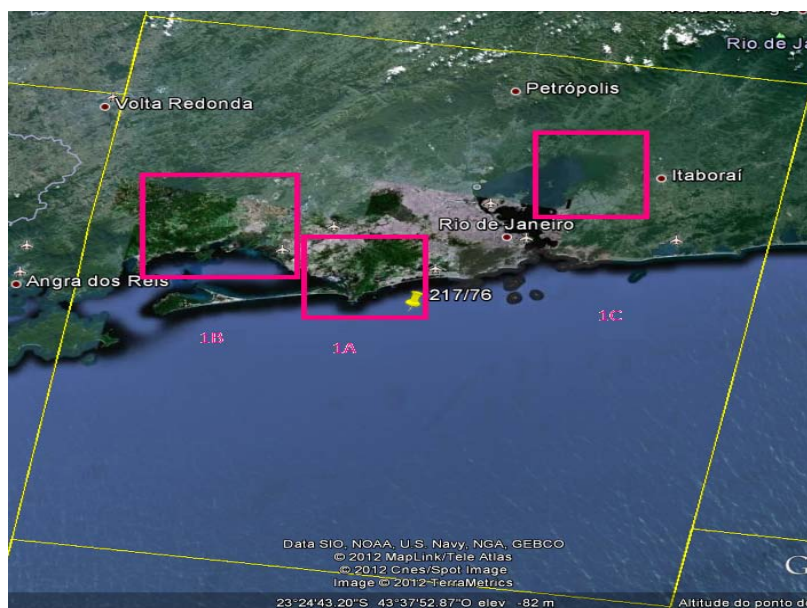


Figura 11 - Cena 217/76 do LANDSAT-5 com realce, em rosa, dos recortes das imagens 1A, 1B e 1C (modificada de GOOGLE EARTH, 2012).

Os recortes da cena foram estipulados com base nos padrões das classes de interesse, isto é, em cada recorte estão presentes diversos aspectos de todas as classes de interesse para teste da integração proposta (item 2.2). A classe determinante para a delimitação da área final dos recortes foi a classe Manguezal, um dos ecossistemas mais importantes do planeta, que é de vital importância para o equilíbrio ecológico do meio ambiente devido a sua grande biodiversidade e condições típicas (como a grande umidade), sendo a maior área de berçário natural de aves, moluscos, peixes e crustáceos (possui condições ideais para a reprodução, eclosão, criadouro e abrigo destes animais): o manguezal é considerado um dos mais produtivos ambientes naturais do Brasil (NANNI; NANNI; SEGNINI, 2005) Esta classe está presente, distintamente, em somente três áreas da cena selecionada, as quais foram exatamente as escolhidas para a realização dos recortes.

Os recortes foram feitos no programa IDRISI através dos seguintes passos (Figura 12):

- a) As bandas 1 a 5 e 7 do LANDSAT-5 foram importadas para o IDRISI através da função *File* → *Import* → *Government/ Data Provider Formats* → *Landsat ETM*, para cada uma das bandas baixadas do INPE (2009);
- b) De forma a se obter recortes exatamente iguais para todas as bandas, estas foram agrupadas em um único grupo *raster* do IDRISI denominado CAT-1

através da função *Create* → *Raster Group*, dentro do Idrisi Explorer (à direita na Figura 13);

- c) Com o grupo de bandas formado, utilizou-se uma composição da cena para ver qual a área desejada para recorte, no exemplo foi utilizada uma composição colorida R4G5B3 da cena para aplicar uma janela de zoom através da função *Zoom Window*, situada na barra de atalhos do programa;
- d) Com a janela da cena sendo aquela desejada, selecionou-se a função *Reformat* → *Window*, onde apareceu a tela WINDOW (*image windowing*) onde foi selecionado o grupo CAT-1 em *Insert layer group*; em *Window specified by* foi selecionado *An existing windowed image*, que mostrou no lado direito, da mesma tela, as coordenadas do recorte realizado; e
- e) Foi selecionado um prefixo para nome dos recortes em *Output prefix*.

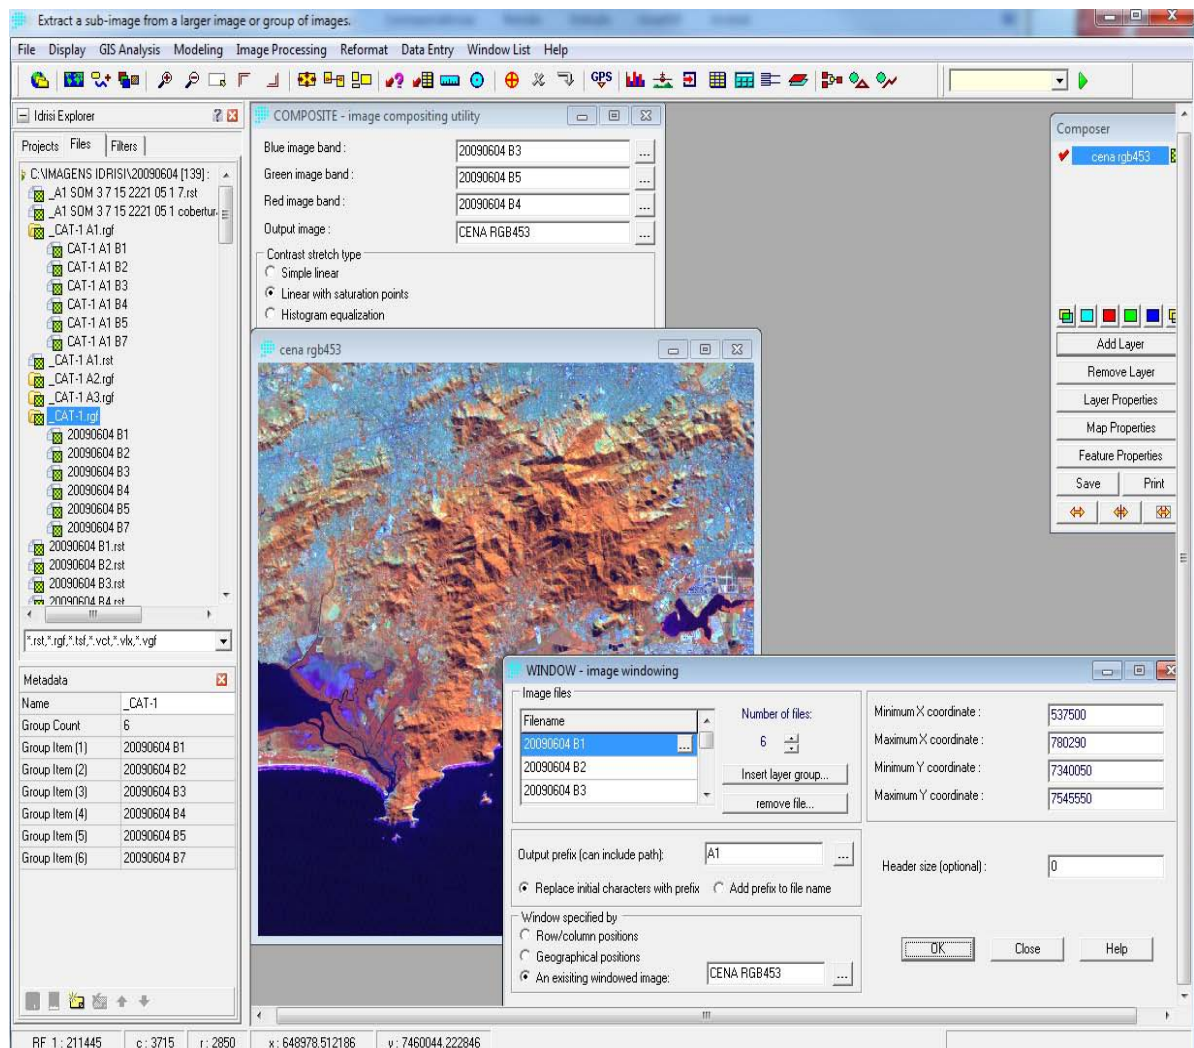


Figura 12 - Tela do IDRISI para feitura do recorte 1A – Guaratiba.

2.1.3.1 Recorte 1A – Guaratiba

Este recorte (Figura 13) possui 1016 colunas e 783 linhas, significando, aproximadamente, 716 km² de área (30m por pixel). A região do recorte abarca parte do município do Rio de Janeiro (Figura 14), sendo os seguintes bairros completamente inclusos na imagem: Barra de Guaratiba, Pedra de Guaratiba, Curicica, Camorim, Vargem pequena, Vargem Grande, Recreio dos Bandeirantes e Grumari. Os bairros de Paciência, Cosmos, Inhoaíba, Guaratiba, Campo Grande, Senador Vasconcelos, Senador Camará, Bangu, Padre Miguel, Realengo, Jardim Sulacap, Joá, Tanque, Taquara, Jacarepaguá, e Barra da Tijuca não estão completamente contidos na imagem deste recorte. O destaque deste recorte é o Parque Estadual da Pedra Branca, com vegetação típica da Mata Atlântica e cerca de 12.500 hectares de área (CIDE, 2009).




Figura 13 - Recorte 1A, Guaratiba, da cena analisada, com composição R3G4B5. Escala aproximada: 1:250.000.

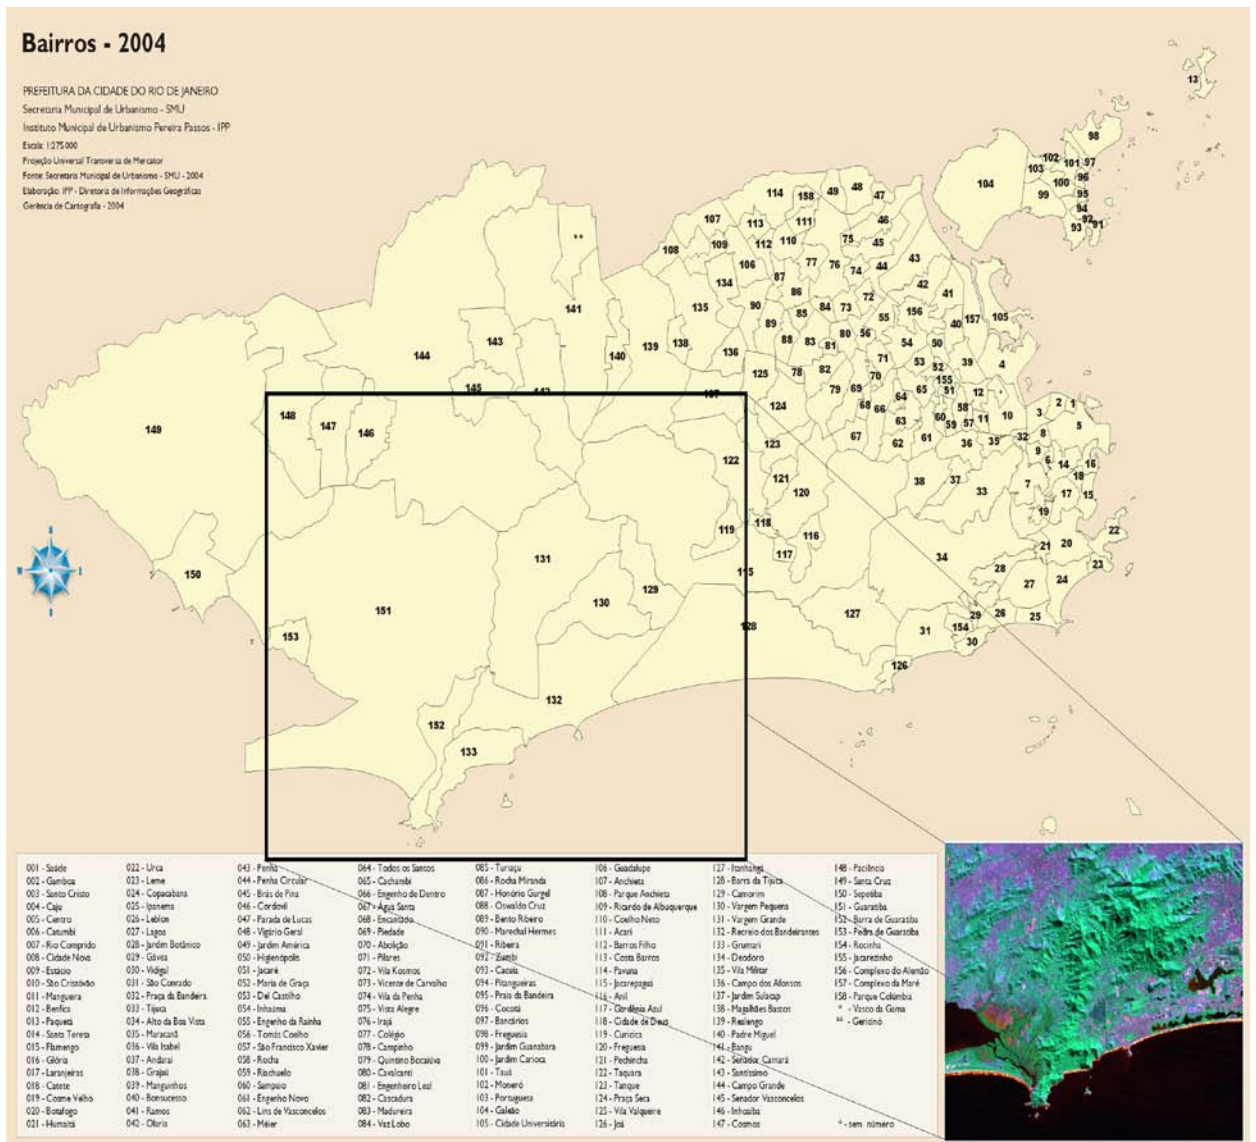


Figura 14 - Bairros da cidade do Rio de Janeiro no recorte 1A – Guaratiba (modificada CIDE, 2009).

A Figura 15 apresenta os destaques deste recorte realçados: a presença de duas áreas de apicum (tonalidade roxo alaranjado), realçadas na cor vermelha, que são áreas planas de elevada salinidade ou acidez, desprovidas de cobertura vegetal – apicum propriamente dito, característico da presença de manguezal próximo; é possível a diferenciação entre as classes Água Particulada e não Particulada na esquerda da Lagoa de Jacarepaguá, em dois pontos da Lagoa de Marapendi e na parte esquerda inferior da imagem, com realce na cor amarela; o realce na cor vinho destaca o Maciço da Pedra Branca e na cor marrom o Parque Estadual da Serra Branca. A Área Construída apresenta-se com tonalidades que vão do rosa ao lilás. Nesta composição todos os corpos hídricos presentes se apresentam na cor preta.




Figura 15 - Recorte 1A com realce de características gerais da área.

2.1.3.2 Recorte 1B – Mangaratiba



Figura 16 - Recorte 1B, Mangaratiba, da cena analisada, com composição R5G4B3. Escala aproximada: 1:250.000.

Este recorte (Figura 16) possui 1395 colunas e 926 linhas, significando, aproximadamente, 1.163 km² de área (30m por pixel), englobando os municípios do Rio de Janeiro, Mangaratiba, Itaguaí, Rio Claro, Piraí e Sepetiba.

Na Figura 17, na parte do mapa, observa-se que os corpos hídricos em destaque neste recorte são os da Baía de Sepetiba (parte azul clara na parte de baixo), a Represa de Ribeirão das Lajes (cor azul clara no continente) e o Rio Guandu (cor verde). A ilha de Itacuruçá (assinalada em amarelo), o Porto de Sepetiba (circundado em vermelho) e as empresas NUCLEP – Nuclebrás Equipamentos Pesados S. A., Furnas (situada às margens do Rio Guandu) e a Cosigua Gerdau, todas com realce na cor laranja, são os destaques da área.

Na parte da imagem de satélite são assinaladas, em branco, as áreas com Água Particulada, que apresentam uma cor azul escuro nesta composição. A Área Construída apresenta tons que vão do rosa ao lilás. As duas áreas circundadas de vermelho (formato do número oito deitado) são nuvens.

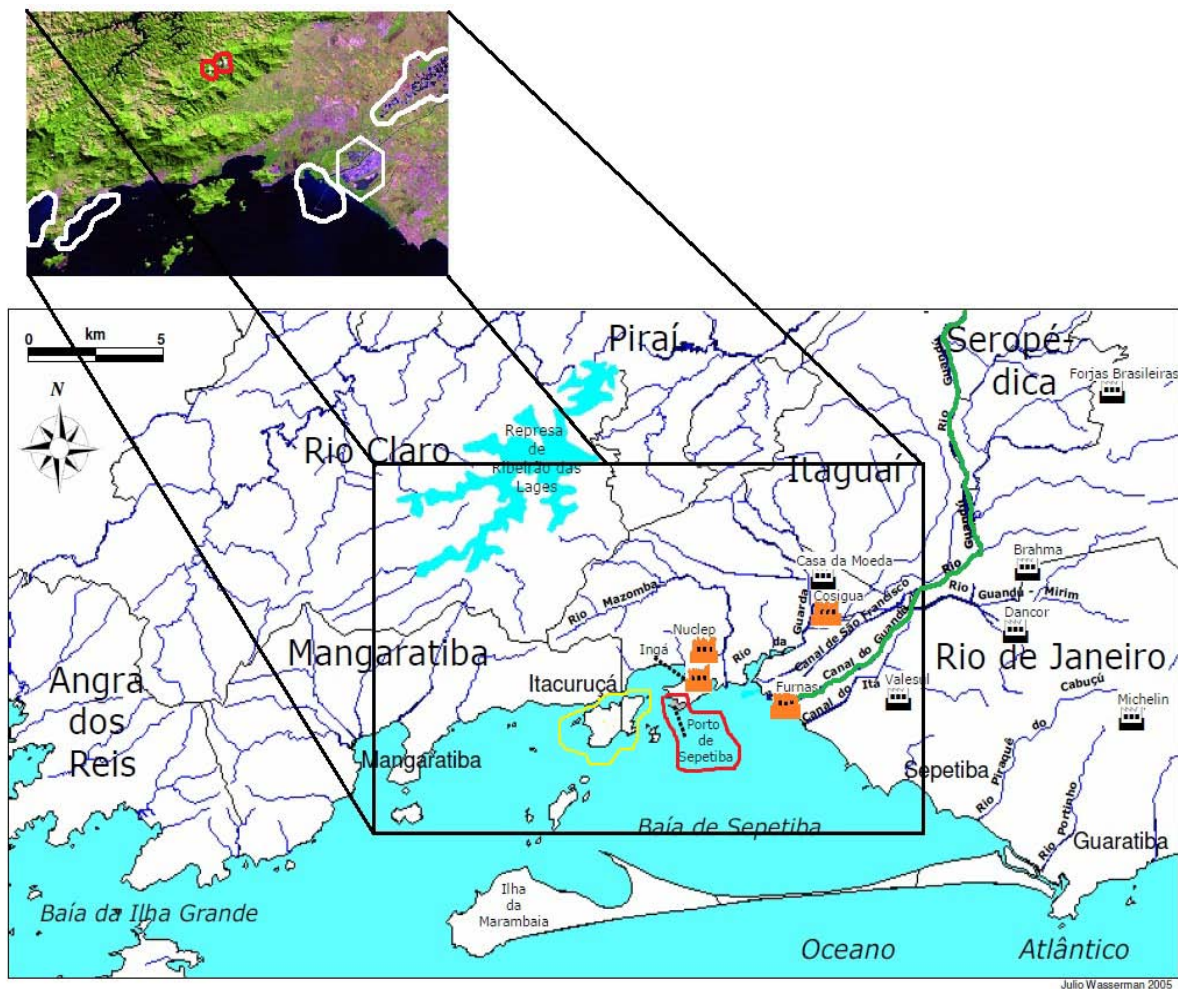


Figura 17 - Realce de características gerais da área do recorte 1B – Mangaratiba (modificado de WASSERMAN, 2005, p. 10).

2.1.3.3 Recorte 1C – Magé




Figura 18 - Recorte 1C, Magé, da cena analisada, com composição R4G5B7. Escala aproximada: 1:250.000.

O recorte possui 864 colunas e 770 linhas, significando, aproximadamente, 600 km² de área (30m por pixel), compreendendo parte dos municípios de Magé, Guapimirim, Itaboraí e São Gonçalo. Os destaques deste recorte, representado na Figura 18, é a APA (Área de Proteção Ambiental) de Guapimirim, criada com o objetivo de proteção dos últimos remanescentes de manguezais do fundo da Baía de Guanabara, onde se localiza uma extensa área de manguezal, área determinante para escolha deste recorte, e a Estação Ecológica (ESEC) da Guanabara, situada totalmente no interior da APA Guapimirim, criada com o objetivo de preservar os remanescentes de manguezal da Baía de Guanabara, bem como sua fauna e flora associadas. Os corpos hídricos de destaque são a Baía de Guanabara e os Rios Guapi, Graraí, Guaraí-Mirim, Caceribu e Guaxindiba. A Ilha de Paquetá e a do Brocoió destacam-se na baía (CIDE, 2009).

Na Figura 19, em destaque na cor amarela, tem-se a APA Guapimirim e, dentro dela na cor vermelha, a ESEC Guanabara. Os rios Guapimirim, Guaraí, Guaraí-Mirim e Guaxindiba estão marcados na imagem, na cor verde.

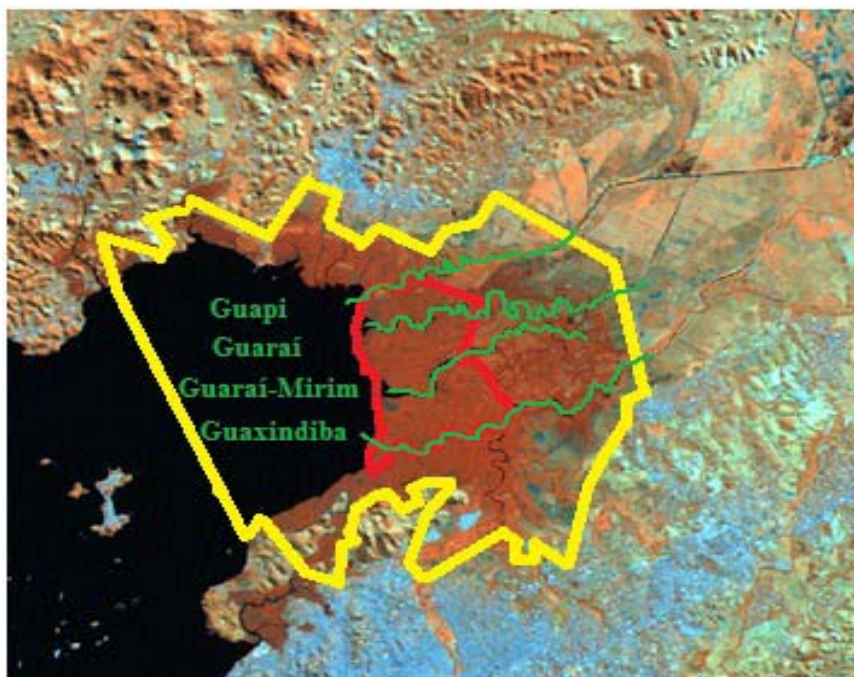


Figura 19 - Recorte 1C com realce de características gerais da área.

2.2 Definição e caracterização das classes em estudo

É necessário destacar que como as imagens dos recortes não comportam áreas somente com a presença das cinco classes de interesse, devido ao extenso tamanho das mesmas e por ser extremamente corriqueira a existência de classes desconhecidas ou não interessantes à análise, foi estipulada uma sexta classe denominada Outros ou Classe Fora do Interesse (CFI), que engloba todas as classes outras que não são do interesse do usuário do integrador. Esta classe foi utilizada tanto pela especialista, como pelos sistemas computacionais IDRISI e ENVI, e pelo integrador.

Ressalta-se que a classificação de Anderson *et al.* (1979), que definia nove grandes classes do uso da terra e do revestimento do solo para sensores remotos (Terra Urbana ou Construída, Terra Agrícola, Pastagem, Terra Florestal, Água, Terra Úmida, Terra Árida, Tundra e Neve ou Gelo Perene), amplamente adotada tanto pelo meio acadêmico como no comercial, foi substituída em 2006 pelo IBGE (2006) através do Manual Técnico de Uso da Terra.

Dentre as grandes definições da nova nomenclatura adotada, as listadas a seguir são interessantes para o trabalho a ser realizado, segundo IBGE (2006):

- Áreas Antrópicas Não-Agrícolas: são “todos os tipos de uso da terra de natureza não-agrícola” (IBGE, 2006, p. 25). Dentre estas se destacam as áreas urbanizadas, industriais, comerciais e redes de comunicação;
- Áreas Antrópicas Agrícolas: “a terra agrícola pode ser definida como terra utilizada para a produção de alimentos, fibras e outras *commodities* do agronegócio” (IBGE, 2006, p. 27), incluindo “todas as terras cultivadas, caracterizadas pelo delineamento de áreas cultivadas ou em descanso, podendo também compreender áreas alagadas” (IBGE, 2006, p. 27). Dentre as suas subdivisões destaca-se a silvicultura e reflorestamento;
- Áreas de Vegetação Natural: destacam-se as subdivisões Florestal e campestre;

e

“... compreende um conjunto de estruturas Florestal e campestre, abrangendo desde florestas e campos originais (primários) e alterados até formações florestais espontâneas secundárias, arbustivas, herbáceas e/ou gramíneo-lenhosas, em diversos estágios sucessionais de desenvolvimento, distribuídos por diferentes ambientes e situações geográficas” (IBGE, 2006, p. 29).

- Água: Dentre as suas subdivisões destacam-se corpos d’água continentais, corpos d’água costeiros e represas (reservatórios).

Incluem todas as classes de águas interior e costeira, como cursos d’água e canais (rios, riachos, canais e outros corpos d’água lineares), corpos d’água naturalmente fechados, sem movimento (lagos naturais regulados) e reservatórios artificiais (represamentos artificiais d’água construídos para irrigação, controle de enchentes, fornecimento de água e geração de energia elétrica), além das lagoas costeiras ou lagunas, estuários e baías (IBGE, 2006, p. 32).

Esta nova nomenclatura divide os fenômenos em três níveis: o nível I, as classes, que indicam as principais categorias da cobertura terrestre; o nível II, as subclasses, que abarca a cobertura e o uso em uma escala mais regional; e o nível III, as unidades, que indica os usos propriamente ditos, podendo possuir inúmeras combinações entre os tipos de uso e de cobertura do território nacional.

Observa-se que a nomenclatura adotada pelo IBGE (2006) segue padrões sociais, culturais, econômicos e políticos. Ocorre que o teste da integração proposta visa, somente, a identificação de objetos geográficos, não importando procedência, utilização ou titularidade dos mesmos, somente o que ele é por si próprio. Assim sendo, as classes, subclasses e unidades escolhidas ficarão alijadas de aspectos econômicos, sociais e políticos.

Logo, as classes (nível I) Água, Área Antrópica Não-Agrícola e Área de Vegetação Natural foram as escolhidas para representação no teste do integrador, que, em essência, realizará a classificação de cinco classes/alvos de interesse que espelham somente a cobertura da terra ou solo, não sendo classes de utilização ou de uso da terra ou solo. Dentre estas

classes foram escolhidas as cinco classes/alvos de interesse, discriminadas a seguir e, conseqüentemente, adaptadas de Anderson *et al.* (1979) e IBGE (2006):

- A) Água Particulada: equivale a todos os corpos de água segundo a definição de água constante das grandes definições da nova nomenclatura do IBGE (2006) que possuem partículas, contaminantes, esgotos, dejetos químicos industriais e lixo que alterem significativamente a composição química da água de forma a serem detectados por um sensor multiespectral com resolução de 30m;
- B) Água não Particulada: corresponde a todos os corpos de água segundo a definição de água constante das grandes definições da nova nomenclatura do IBGE (2006), com a ressalva de não possuem partículas, contaminantes, esgotos, dejetos químicos industriais e lixo que alterem significativamente a composição química da água de forma a serem detectados por um sensor multiespectral com resolução de 30m;
- C) Área Construída: corresponde àquela área indicativa do uso e da presença do homem, possuindo grande parte de sua superfície coberta por estruturas. Inclui-se metrópoles, cidades, vilas, quaisquer edificações e construções, áreas residenciais, industriais, comerciais e instituições, inclusive aquelas que possam estar situadas isoladamente das áreas urbanas;
- D) Vegetação Primária e Secundária (Florestal): caracterizada por florestas intocadas (ou aquela onde a ação antrópica não provocou significativas alterações em suas características originais de estruturas e espécies) e por florestas resultantes de um processo de regeneração natural da vegetação, seja por ação antrópica (corte raso da floresta para agricultura ou pastagem) ou por causas naturais. Em média, apresenta uma densidade de cobertura das copas acima, e inclusive, de 10%, significando uma influência no clima e no regime hídrico da região entorno destas; e
- E) Manguezal: ecossistema essencialmente úmido característico de regiões tropicais e subtropicais, encontrado nas zonas costeiras, sendo local representativo de transição entre os ambientes terrestre e aquático. Os manguezais promovem a fixação do solo, impedindo a erosão e estabilizando a linha costeira através de suas raízes que funcionam como filtros para a retenção de sedimentos (são úteis na recuperação de áreas degradadas).

Ambiente caracterizado pela associação de árvores e arbustos (*Rhizophora mangle*, *Laguncularia racemosa*, *Avicennia* sp.), todas plantas halófitas, que se desenvolvem em planícies de marés ("tidal flats") protegidas margeando lagunas e estuários de regiões quentes e úmidas. Os substratos desses ambientes são, em geral, lamosos e ricos em matéria orgânica (organic matter) (SUGUIO, 1998, p. 488).

Como padrão de cores associado às classificações obtidas tanto pela especialista, como pelos sistemas computacionais IDRISI e ENVI, e pelo integrador, frente às seis classes selecionadas, temos:

- Classe Água Particulada: cor marrom;
- Classe Água não Particulada: cor azul;
- Classe Área Construída: cor vermelha;
- Classe Vegetação Primária e Secundária (Florestal): cor verde;
- Classe Manguezal: cor amarela;
- Classe Sedimento: cor branca (presente somente na primeira área-teste);
- Outros (item 2.1.2) ou Classes Fora do Interesse (CFI): cor preta.

Segundo SUGUIO (1998, p. 803) sedimento é:

Agregado inconsolidado de partículas minerais ou de rochas formado na superfície terrestre. O sedimento pode ser classificado segundo vários critérios. De acordo com a origem é possível reconhecer os sedimentos clástico, químico e orgânico. Pelas sua composição química pode-se falar em silício, carbonático, orgânico, etc. É também possível combinar as duas classificações anteriores como, por exemplo, no caso do sedimento siliciclástico.







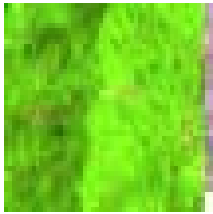



Aqui cabe salientar que a classe Sedimento foi uma classe incorporada desde a definição das classes. Ocorreu que quando da classificação pela especialista do segundo e do terceiro recorte, foi verificado que tal classe não apresentava relevância na área destes recortes a ponto de justificar sua classificação. Então, optou-se por manter esta classe para a classificação do primeiro recorte, mas com a sua retirada das classes de interesse (já que não atende a todos os recortes da área-teste) e do cálculo do índice Kappa.

2.2.1 Interpretação visual



A Interpretação de Imagens tem por objetivo realizar o levantamento dos objetos ou elementos de interesse de uma imagem, isto é, obter a significância (aspecto qualitativo) dos mesmos. Estes elementos de reconhecimento podem ser discerníveis através de parâmetros como tonalidade e cor, forma e tamanho, padrão, associação, textura e sombra. (ANDERSON, 1982; CONWAY, 1967).

Tais elementos formam a base para a formação da chave de interpretação ou classificação, com a descrição e ilustração dos alvos de interesse, servindo de guia para que se possa identificar os objetos desejados em uma imagem.

O Quadro 2 abaixo apresenta um exemplo de chave de interpretação utilizada pela especialista para os recortes.

Classe	Descrição em campo	LANDSAT-5 (R5G4B3)	Característica no campo
Água Particulada	<u>Cor</u> : tons de azul escuro, chegando quase a cor preta. <u>Textura</u> : pouco lisa. Corpos d'água com contaminantes sensíveis para resolução 30m.		
Água não Particulada	<u>Cor</u> : preta. <u>Textura</u> : lisa. Corpos d'água com contaminantes sensíveis para resolução 30m.		
Área Construída	<u>Cor</u> : tons de rosa e lilás. <u>Textura</u> : granulada. Construções e edificações, com formas assimétricas e descontínuas.		
Florestal	<u>Cor</u> : verde clara. <u>Textura</u> : rugosa, grosseira. Florestas intocadas ou em regeneração.		
Manguezal	<u>Cor</u> : verde escura mesclada com marrom. <u>Textura</u> : marmorizada. Ecossistema característico do encontro de rios com o mar ou na linha de costa.		

continua

Classe	Descrição em campo	LANDSAT-5 (R5G4B3)	Característica no campo
Sedimento	<u>Cor</u> : branca. <u>Textura</u> : fina. Material granulado formado pela erosão de rochas (basicamente sílica).		

Quadro 2 - Exemplo dos elementos de interesse para a cena LANDSAT-5, utilizada pela especialista nos recortes da área-teste, composição R5G4B3.

A verdade terrestre foi determinada pela especialista em imagem, Prof^a. María Elena Iannarelli (com Notório Saber pela SELPER – Sociedade Latinoamericana de Especialistas em Sensoriamento Remoto), com mais de 35 anos de experiência na área de interpretação de imagem de satélites e em fotointerpretação (dentre os variados projetos trabalhados destaca-se o Projeto RADAMBRASIL), e com dezenas de interpretações e estudos realizados no Estado do Rio de Janeiro (amplo conhecimento da área e das classes de interesse analisadas).

A Figura 20 apresenta o fluxograma de trabalho da especialista em imagem para melhor entendimento do processo realizado para a interpretação dos recortes e a análise espectral efetuada que serão explicados a seguir.

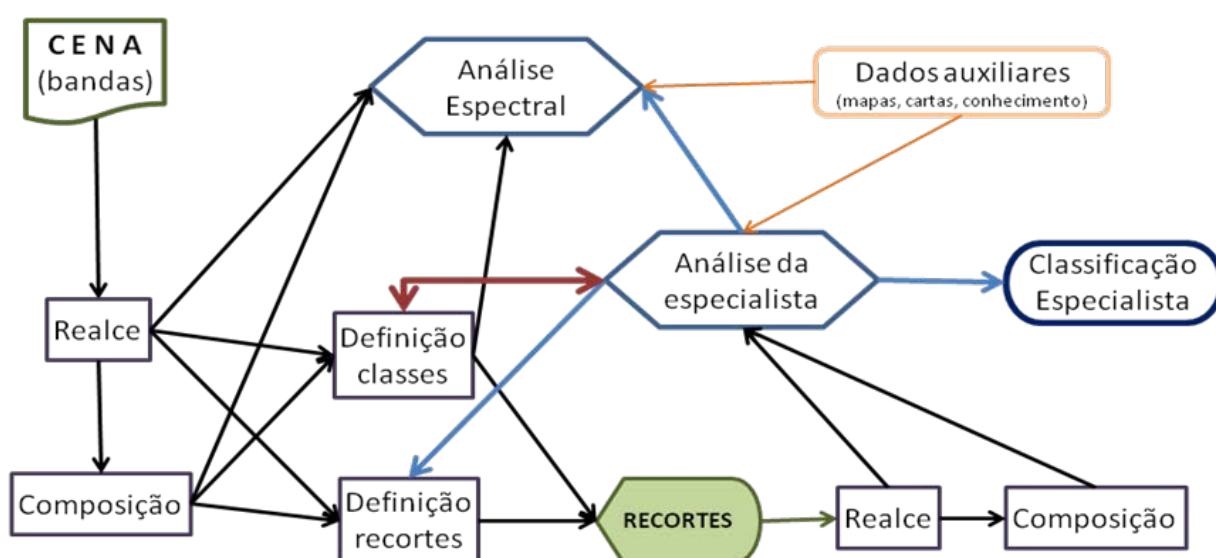


Figura 20 - Fluxograma de trabalho realizado pela especialista em imagens para a geração das classificações e para a análise espectral.

Nas imagens das bandas da cena escolhida e das bandas dos recortes foi aplicada a técnica de realce de contraste com o objetivo de melhorar a qualidade visual das imagens para a observação das características da imagem, que são critérios extremamente subjetivos do olho humano e, conseqüentemente, variáveis de especialista para especialista. Para a realização desta etapa foram utilizadas as funções HISTO (*image histogram*) e STRETCH (*contrast stretch utility*) do programa IDRISI. A função HISTO (*Display* → HISTO) fornece um gráfico de distribuição estatística dos níveis de quantização dos pixels presentes na imagem – o histograma. Com base neste gráfico e na experiência adquirida com utilização de imagens do LANDSAT-5, a especialista estipulou os valores mínimo e máximo para os pixels da imagem de saída de cada uma das bandas da cena e dos recortes, os quais foram utilizados na função STRETCH (*Display* → STRETCH) para o realce final das mesmas. Florenzano (2002), Novo (2008), Moreira (2005) e IDRISI (2012) fornecem subsídios para um estudo mais avançado neste tópico.

A realização de variadas composições entre as bandas da cena e as bandas dos recortes é necessária para a análise visual da especialista, por ser mais um discriminador para as classes analisadas, que requisitou a composição de várias bandas tal qual o especificado por Florenzano (2002) e INPE (2012), a saber (para o sistema RGB):

- Bandas 1, 2 e 3: onde as composições aparecem como se fosse fotografias da área (falsa-cor), com boa penetração em corpos d'água, o que proporciona o realce de sedimentos, correntes e turbidez dos mesmos; a vegetação apresenta tonalidades esverdeadas. A variante desta composição – bandas 3-2-1 – gera uma composição de cores “verdadeiras”, pois as bandas estarão nos canais das cores correspondentes;
- Bandas 2, 3 e 4: as composições apresentam uma delimitação bem marcada entre solo e água, a vegetação se apresenta em tonalidades avermelhadas; variante utilizada 4-3-2;
- Bandas 3, 4 e 5: nestas composições a vegetação aparece mais discriminada, com tonalidades esverdeadas e rosadas, e os limites entre solo e água são distinguíveis; variante utilizada 5-4-3; e
- Bandas 2, 4 e 7: as composições apresentam a vegetação em tons esverdeados, sendo possível a discriminação da umidade na vegetação e no solo; variante utilizada 7-4-2.

Estas quatro composições e suas variações foram realizadas no programa IDRISI através da função COMPOSITE (*imagem compositing utility*, acessada através de *Display* →

COMPOSITE) que produziu uma imagem falsa-cor através da aplicação de uma banda do LANDSAT para cada canal de cor, de acordo com o sistema RGB (*Red-Green-Blue*), sendo a tela do programa apresentada na Figura 21.

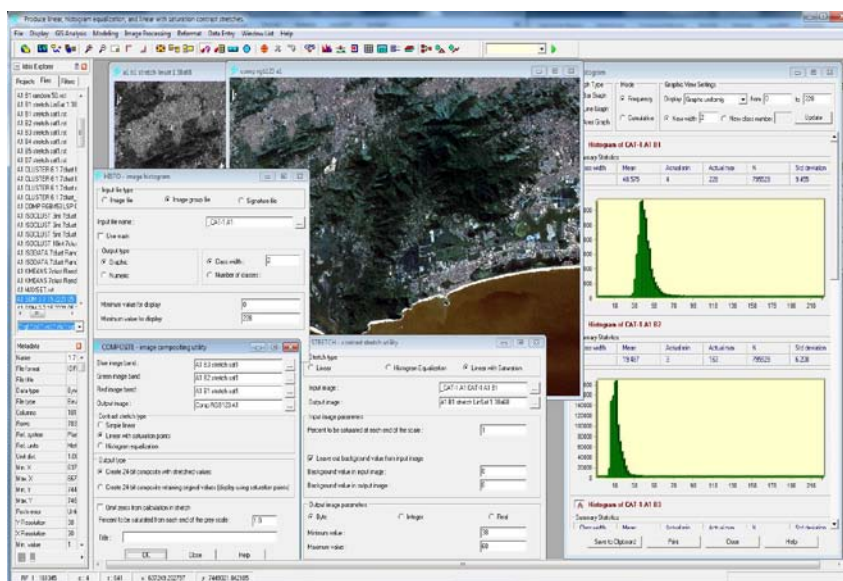


Figura 21 - Tela do programa IDRISI com as funções STRECTH, HISTO e COMPOSITE.

A explicitação da feitura dos três recortes da cena da área-teste foi demonstrado no item 2.1.3. Deve ser ressaltado que as etapas de realce, composição e recorte não alteram os valores dos pixels da imagem da cena original.

Com as bandas da cena realçadas e com as composições derivadas destes realces a especialista definiu primeiramente as classes e a partir da definição destas é que os recortes foram definidos. Com os recortes feitos, as respectivas bandas de cada um destes três recortes foram também realçadas em contraste, e, posteriormente, estas foram utilizadas para a realização das composições dos recortes. Toda esta operação foi realizada do mesma forma que o descrito anteriormente para a cena escolhida, seguindo as determinações da especialista em imagens.

A análise espectral foi realizada com base nos realces e composições da cena escolhida e nas classes estipuladas, sendo que a escolha dos pixels inequívocos para cada uma das cinco classes pela especialista foi realizada de modo que cada classe não contivesse mais de cinco representantes em cada um dos recortes, significando que para cada classe tem um conjunto de 30 pixels, sendo que cinco destes são do recorte 1A, cinco do recorte 1B, cinco do recorte 1C e os restantes 15 pixels de outras partes da cena. Ocorre que tal procedimento pôde ser realizado para cada uma das classes com a exceção da classe Manguezal, pois todos os pixels inequívocos desta se encontram somente dentro dos recortes realizados. A escolha destes

pixels foi realizada pela especialista (Figura 22), com a seleção tanto de pixels “puros”, quanto dos pixels “misturados” (explicitado no item 1.2.4).




Figura 22 - Realce dos 30 pixels escolhidos para cada classe na cena analisada.

Com as classes estipuladas, as bandas realçadas e as respectivas composições prontas, a especialista realizou a classificação de cada um dos recortes da área-teste, utilizando somente os registros espectrais da cena – a interpretação visual – e seu conhecimento acumulado da região, adquirido através de décadas de trabalho, resultado de sua comprovada competência no ramo. Ressalta-se que tais dados auxiliares também foram utilizados para a análise espectral. A interpretação realizada para cada um dos recortes da área-teste foi parcial, também chamada de método comparativo de interpretação com chave de interpretação pelo método seletivo (item 2.1.2), uma vez que há mais classes nas áreas do que as cinco classes de interesse deste trabalho: as demais classes foram estipuladas como Outros ou Classes Fora do Interesse (CFI). As cores utilizadas para a classificação segue o exposto no item 2.2.

Ressalta-se que as classificações realizadas pela especialista de imagem demandaram uma média de 30 horas de trabalho para cada recorte da área-teste. A análise espectral demandou cerca de 8 horas de trabalho. As classificações da especialista serviram de base para os ajustes do integrador.

2.3 Sistema computacional IDRISI

O IDRISI é um sistema computacional que integra funcionalidades e tecnologias direcionadas às aplicações em sistema de informações, de modelagem geográfica, de processamento de imagens e ferramentas de suporte à decisão. Com dezenas de módulos que abarcam um grande número de operações analíticas, desde as ferramentas mais básicas (como cálculo de distâncias, visualização e conversão de dados dos mais variados tipos) até as ferramentas mais sofisticadas para análises complexas, como planejamento territorial, análise de superfície, modelagem espacial e estatística espacial (IDRISI, 2012). O diferencial deste sistema é possuir uma interface com o usuário amigável, além do baixo custo em comparação com os sistemas similares (IDRISI, 2012).

O nome IDRISI advém de um famoso cartógrafo e geógrafo árabe muçulmano, que viveu no século XII, chamado Abu Abd Allah Muhammed al-Idrisi, que liderou um levantamento geográfico e cartográfico do mundo conhecido (Europa, África, Oriente Médio e Ásia Central) por mais de 15 anos, sendo que os mapas e textos resultantes serviram como material de referência por mais de 500 anos.

Este sistema foi desenvolvido em 1987 na Universidade de Clark, em Massachussets, nos Estados Unidos da América do Norte (EUA), pelo Prof. J. R. Eastman para complementação de suas aulas de graduação em Geografia, sendo somente um conjunto de programas individuais para utilização nas atividades acadêmicas. A partir de 1988/89 ele foi transformado em um sistema computacional e desenvolvido pela Clark *Labs*. Devido a seu local de origem, o IDRISI possui muitas ferramentas de apoio à decisão para gestão ambiental, sendo é muito utilizado para análises ambientais e no planejamento sustentável de recursos minerais. A última edição ou versão – a 17ª edição – chamada Selva, foi lançada em janeiro de 2012 trazendo novas funcionalidades e incrementos a funcionalidades já existentes, como, por exemplo, uma modelagem específica para a observação e análise de séries temporais em imagens (*Earth Trends – ETM*) (IDRISI, 2012).

No que tange ao processamento de imagens, especificamente na classificação de padrões em imagens multiespectrais para comparação com o integrador proposto, a versão Selva não possui diferença para a Taiga – a 16ª edição – que apresenta uma interface bem próxima as das versões anteriores. Logo, a versão do IDRISI utilizada foi a Taiga.

No presente estudo foram utilizadas duas funções, que de acordo com IDRISI (2012), tem as seguintes características:

- a) Função CLUSTER: utiliza a técnica de seleção dos diferentes agrupamentos (cluster) de dados pelos picos do histograma (cada pico é definido como o valor de maior frequência em relação aos seus vizinhos). Depois da identificação dos picos, todos os valores são associados ao pico mais próximo, o que leva as divisões entre as classes tenderem a cair no ponto médio entre os picos. Logo, ele parte somente da análise das bandas em si, sem a entrada de novos dados pelo usuário, como o integrador. Esta função não se utiliza de técnicas de IC que incorporem o conhecimento de especialista para a classificação, utilizando algoritmo probabilístico sem base em conhecimento adquirido em análise de imagem; e
- b) Função ISOCLUST: baseada nos mesmos conceitos das rotinas da ISODATA (proposta por Ball e Hall em 1985) e dos métodos H-MEANS e K-MEANS, onde o usuário somente o especifica o número de classes desejado, o número de bandas espectrais que serão utilizadas e quantas iterações desejadas – esta função foi escolhida para teste, pois apresentou resultados melhores que a função ISODATA do IDRISI.

Na Figura 23 é apresentada a tela do IDRISI com as funções CLUSTER e ISOCLUST abertas. Para cada recorte foram testadas variações dos parâmetros de cada função de modo a se atingir a melhor classificação possível, que foi escolhida com o auxílio e aval da especialista em imagens.

A função CLUSTER possui cinco parâmetros de entrada, sendo que o número de bandas de entrada e o número máximo de classes foram os mesmos para todas as classificações realizadas (o valor de seis para cada parâmetro). Na experimentação de valores observaram-se dois pontos importantes:

- Depois de várias experimentações, foi notado que o nível fino (*fine*) de generalização da classificação, o qual permite o detalhamento das classes espectrais, obteve melhores resultados que o nível amplo (*broad*) de generalização (visualização geral das classes espectrais como um todo), sendo então estipulado que as demais classificações só utilizariam o nível fino de generalização; e
- Verificou-se que para a entrada de seis bandas, o programa não permitiu a marcação dos níveis de cinza (quantização) para o valor igual a 255, requisitando por meio de mensagem de erro que este número fosse reduzido e

que realizasse o comando do CLUSTER novamente: o número foi reduzido até 9 níveis de cinza, quando só então o programa realizou a operação.

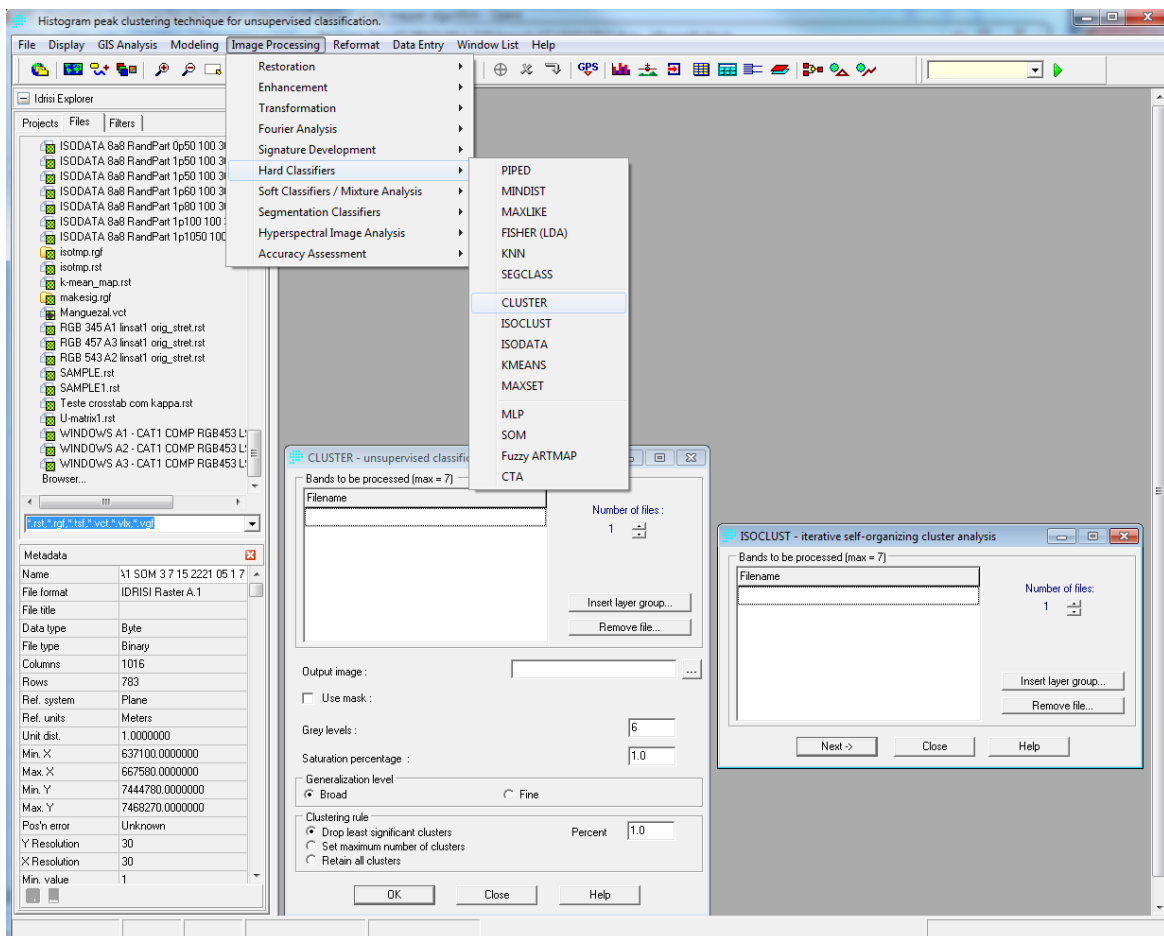


Figura 23 - Tela do IDRISI com as funções CLUSTER e ISOCLUST.

O último parâmetro restante de entrada do CLUSTER, que originou a classificação selecionada, foi saturação igual a zero (a saturação é a percentagem que será saturada para cada final da distribuição de dados para cada banda)

A função ISOCLUST é uma função que apresenta a entrada de quatro parâmetros distintos: o número de bandas desejado para a classificação, o número de iterações que a função irá realizar, o número de classes ou agrupamentos desejados para a classificação e o número de amostras mínimo que o programa irá selecionar para a realização da classificação. Ressalta-se que as iterações representam a aplicação do método de máxima verossimilhança (Maxver) aos agrupamentos.

O número de classes foi o mesmo para a entrada de todos os programas: seis classes – as cinco classes de interesse mais a classe Outros. Idem para o número de bandas: seis. Os

dois parâmetros restantes de entrada que originaram a classificação selecionada foram 10 iterações e 100 amostras.

2.4 Sistema computacional ENVI

O ENVI (*Environment for Visualizing Images*), versão 5.0 (lançado em meados de 2012), da *Exelis VIS (Visual Information Solutions)*, do EUA, é considerado, por muitos, como um dos melhores sistemas computacionais de processamento digital de imagens (PDI) disponível no mercado, pois um dos seus pontos fortes é a análise e processamento espectral, sendo utilizado por diversas instituições brasileiras, como a Companhia de Pesquisa de Recursos Minerais (CPRM), a Universidade de São Paulo (USP) e a Universidade de Campinas (UNICAMP). O ENVI foi desenvolvido com base na linguagem IDL (*Interactive Data Language*), que é de livre acesso, permitindo a customização das funções de acordo com o trabalho desejado (elaboração de rotinas personalizadas) (ENVI, 2011).

Dentre as funcionalidades básicas do ENVI estão à exploração, visualização, análise e apresentação de dados na área de Sensoriamento Remoto (SR) e de Sistemas de Informação Geográfica (SIG). Esta nova versão apresenta novas funcionalidades como, por exemplo, a implementação das ferramentas sequenciais, as *SPEAR (Spectral Processing Exploitation and Analysis Resource)*, como a fusão de imagens e a análise de detecção de mudanças, e o suporte para os satélites GeoEye-1 e KompSat-2.

As funções descritas a seguir seguem a linha das classificações não supervisionadas, que foram aplicadas a blocos ou agrupamentos (*clusters*) de pixels do conjunto de dados (a imagem propriamente dita), baseado somente na estatística destes dados, sem qualquer intervenção ou definição prévia do usuário das classes de treinamento:

- a) Função ISODATA: calcula a média das classes igualmente distribuídas no espaço dos dados e, interativamente, agrupa os pixels através da técnica da distância mínima. A cada interação 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 sejam especificados, 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 do pixel escolhido (ou selecionado), ou até que o número máximo de iterações seja alcançado (TOU e GONZALES, 1974); e
- b) Função K-MEANS: 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, interativamente, reposicionando-os até que seja encontrada a divisão ótima das radiâncias dos pixels (ENVI, 2011). Em verdade o ISODATA e o K-MEANS possuem algoritmos parecidos, diferindo na quantidade de parâmetros (o ISODATA apresenta mais parâmetros de escolha) e sendo o ISODATA baseado na distribuição dos pixels e o K-MEANS na distribuição das médias (sementes) (OHATA; QUINTANILHA, 2005).

A Figura 24 apresenta as telas das funções ISODATA e K-MEANS. Na função ISODATA, a cada iteração são recalculados e reclassificados os pixels, considerando-se, assim, novos valores médios. Há entrada para determinação do máximo desvio padrão em relação a média e o do erro da distancia máxima, se o usuário assim desejar: estes não foram utilizados pois não acrescentaram significância nas classificações. Nesta função, a classificação só será finalizada quando o número de iterações definido for alcançado ou quando for alcançado o critério estipulado para o limiar de mudança ou ponto de convergência (*Change Threshold* - CT – percentual limite de número de pixels que podem mudar de classe durante as iterações): logo, para um CT maior que zero, o número de iterações desejado nunca será realizado completamente.

Para as seis classes desejadas no recorte 1A (Guaratiba), mais a classe Outros, os parâmetros de entrada que geraram uma classificação mais aproximada da classificação da especialista, para a função ISODATA, depois de várias experimentações foram: número de classes mínimo = 7; número de classes máximo = 7; número máximo de iterações = 20; CT = 1; número mínimo de pixels na classe = 1; máximo desvio padrão da classe = 1; distância mínima da classe = 1; e número máximo de pares para mesclagem (fusão de classes) = 2. Para as cinco classes desejadas no recorte 1B (Mangaratiba) e 1C (Magé), mais a classe Outros, os parâmetros de entrada que geraram uma classificação mais aproximada da classificação da especialista foram os mesmos do recorte 1A, com exceção do número de classes mínimo = 6 e do número de classes máximo = 6.

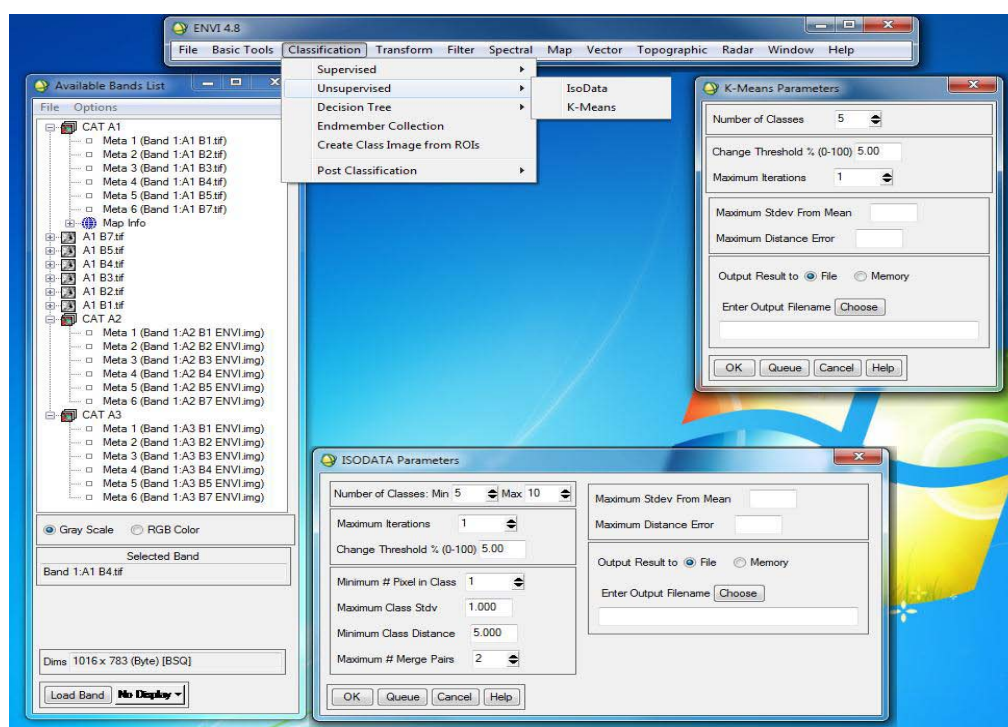


Figura 24 - Função ISODATA e K-MEANS no ENVI.

Para a função K-MEANS, nas seis classes desejadas no recorte 1A (Guaratiba) mais a classe Outros, depois de várias experimentações, os parâmetros de entrada que geraram uma classificação mais aproximada da classificação da especialista, foram: número de classes = 7; CT = 5 e número máximo de iterações = 20. Para as cinco classes desejadas no recorte 1B (Mangaratiba) e 1C (Magé), mais a classe Outros, os parâmetros de entrada que geraram uma classificação mais aproximada da classificação da especialista foram os mesmos do recorte 1A, com exceção do número de classes = 6.

2.5 Integração proposta

2.5.1 Complexidade da cena

Nesta integração, as seguintes palavras-chave são de extrema importância: *Natureza*, *Conhecimento*, *Modelagem*. A correta correlação e interação entre os elementos deste trinômio é a resposta a ser perseguida. A Natureza é expressa pelo objeto geográfico que se deseja analisar, conhecer. O Conhecimento é aquele advindo dos especialistas, o qual deve ser criteriosamente compreendido para que a sua Modelagem seja a mais fiel possível. A compreensão da Natureza de forma que a sua Modelagem seja o mais fidedigno possível

também é necessária, mas a Natureza é essencialmente composta por incerteza e complexidade (MENESES; NETTO, 2001). Segundo Meirelles, Câmara e Almeida (2007) a separação entre biomas distintos não ocorre de maneira abrupta, pois existe uma zona de transição entre eles que não pode ser caracterizada totalmente como pertencente a uma classe específica somente.

Segundo Morin, Ciurana e Motta (2007), a complexidade, em resumo, é uma abordagem do mundo onde este é analisado como um todo indissociável, sendo a formação do conhecimento construída, conseqüentemente, segundo uma abordagem multidisciplinar, que é o que se pretende com esta integração. Ela se contrapõe à *causalidade* (conjunto de todas as relações de causa e efeito) por abordar os fenômenos como uma totalidade orgânica. Assim sendo, não se pode esperar um bom resultado de métodos que utilizem somente raciocínios lógicos, lineares e, essencialmente, monodisciplinares para a resolução de problemas que envolvam complexidade, como é realizado pela maioria dos programas computacionais disponíveis no mercado atual: vide, como exemplo, os métodos clássicos MaxVer e ISODATA, muito utilizados em classificação de padrões, que se utilizam de funções estatísticas puras, isto é, as ligações entre os elementos do terreno e seus atributos na imagem estão implicitamente baseadas em conceito de pertinência de teoria dos conjuntos clássica (lógica *booleana*). No entanto, os objetos geográficos não existem em classes discretas, mas estão ao longo de um todo, do contínuo, significando que os tipos adjacentes de cobertura da terra raramente serão separados por limites rígidos, nitidamente definidos, mas sim por zonas de transição (ZHANG; STUART, 2001).

Dáí o porquê da integração proposta ser essencialmente baseada no conhecimento humano, adquirido através da experiência (observação e correlação de fatos, causas e efeitos da natureza dos objetos geográficos), que foi modelado por técnicas de inteligência computacional que permitem ilações mais próximas ao real, ao natural. Estes princípios, este tripé – *Natureza-Conhecimento-Modelagem* – é que forneceram as bases para a análise da realidade desejada de forma que a complexidade inerente a estes princípios foi modelada mais próxima do “natural”.

2.5.2 Integração proposta

Jensen (2009) expressou bem a presente proposta da integração:

Alguns cientistas extraem novas informações temáticas diretamente da imagem de sensoriamento remoto mesmo sem nunca usar explicitamente a lógica indutiva ou dedutiva. Eles estão interessados apenas na extração da informação a partir da imagem usando métodos

e tecnologias apropriadas. Esta abordagem tecnológica não é tão rigorosa, mas é comum no sensoriamento remoto. E também pode gerar novos conhecimentos (JENSEN, 2009, p. 10).

A Figura 25 apresenta o esquema da integração proposta, sendo seus blocos principais explicados a seguir.

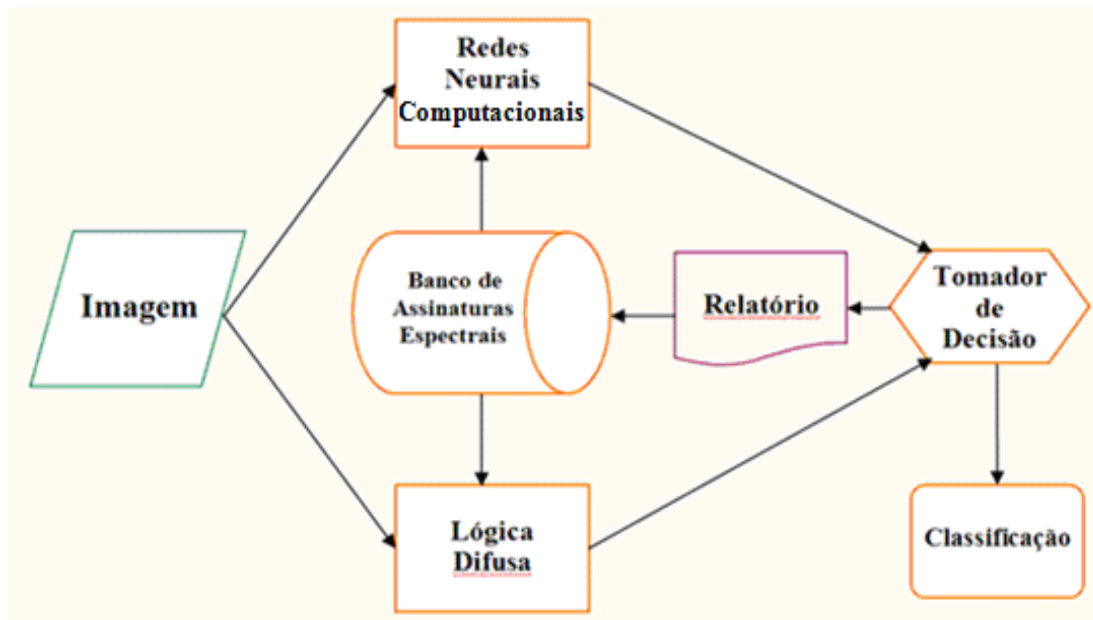


Figura 25 - Esquema da integração proposta (modificada de TEIXEIRA, 2010, p. 386).

As técnicas de IC inseridas na integração proposta visam promover, quanto aos padrões desejados, o aprendizado, a aplicação do conhecimento adquirido através da experiência, o tratamento com situações complexas (os padrões de um objeto geográfico possuem natureza complexa, pois são naturais e a natureza é essencialmente complexa), a resolução de problemas na falta de informações (que é exatamente a pedra “filosofal” da classificação automática de imagens) e a reação rápida e eficiente a novos estímulos.

A integração proposta compreende dois princípios básicos: a utilização de seis bandas do sensor LANDSAT-5 – da mesma forma que a especialista de imagem – representadas na forma de assinaturas espectrais digitais das classes ou alvos de interesse, baseadas na análise espectral do sensor em uso; e a incorporação dos conhecimentos adquiridos por estes mesmos especialistas em um algoritmo, por meio de Inteligência Computacional, de forma a este emular o trabalho destes profissionais. Para que tal integração alcance determinação automática, isto é reconhecimento e classificação automática de padrões, objetos, alvos ou feições (pertencentes às classes de interesse do usuário), ela, em seu estágio inicial de implementação, parte de classificações híbridas ou semiautomáticas, as quais são ajustadas de forma que as sucessivas classificações resultantes tendem a se tornarem automáticas

(frequência de utilização da integração) através da ampliação da base de dados (inclusão de novos conhecimentos e cenas multiespectrais – especificamente, os registros digitais multiespectrais – advindas de imageamento orbital), o que permite a análise, a aprendizagem e a consequente especialização da integração.

O cerne da integração reside na utilização conjunta do reconhecimento de padrões radiométricos (aos valores espectrais dos pixels da imagem analisada – Análise Espectral) com técnicas de IC, dispostos nos seguintes módulos:

- Um Banco de Assinaturas Espectrais (BAE) implementado com parâmetros definidores, para cada banda do sensor utilizado (no caso, o LANDSAT-5), dos valores e correlações radiométricas (quantizações) das classes desejadas (TEIXEIRA, 2008; CASANOVA *et al.*, 2007), o que inclui os conjuntos de treinamentos e regras para o MRNC e para o MLD;
- Um Módulo de Redes Neurais Computacionais (MRNC) implementado com as quantizações definidas por bandas e pelas classes desejadas derivados do BAE com o concurso da especialista (TEIXEIRA, 2004, 2010);
- Um Módulo de Lógica Difusa (MLD) implementado com as quantizações definidas por bandas e pelas classes desejadas – derivadas do BAE – com o auxílio da especialista, sendo então gerados conjuntos de regras (TEIXEIRA, 2004, 2010); e
- Um Módulo Tomador de Decisão (MTD) onde ocorrerá o cotejo das saídas do MRNC e MLD, com a geração de um relatório para que o usuário, se assim o desejar, corrija a classificação (TEIXEIRA, 2004, 2010).

Como podem ser observados na Figura 25, os módulos se comunicam da seguinte forma:

- As entradas do integrador são os módulos MRNC e MLD;
- O BAE se comunica tanto com o MRNC, quanto com o MLD, de forma a fornecer regras e conjuntos de treinamento para os módulos;
- As saídas do MRNC e MLD são submetidas ao MTD; e
- A saída do sistema é composta por uma imagem resultante das classificações realizadas pelos dois módulos e por um relatório.

O BAE, o MRNC e o MLD foram implementados com as quantizações definidas por bandas das classes, de acordo com os conhecimentos de especialista em imagem, que

conduziu a análise espectral. Com base nestes dados, foram gerados os conjuntos de treinamento P e V e o de regras.

Ressalta-se que o integrador realiza somente classificação daqueles padrões em acordo com a análise espectral, isto é, ele não ‘força’ a associação de um determinado padrão de pixel a se “encaixar” em uma das classes de interesse, classificando os padrões em “desacordo” com a análise espectral como Outros ou Classe Fora de Interesse (CFI).

Para o treinamento do sistema foram utilizados os três recortes realizados na cena escolhida, com todas as seis bandas presentes, de modo que, com base nestes registros digitais, a integração realizou inferências baseadas somente no conhecimento implementado previamente nos módulos principais, quando da entrada da primeira imagem. Ao final desta entrada, a especialista em imagem corrigiu a classificação realizada, de forma que, após sucessivas reentradas, a imagem foi classificada de acordo com as classes de interesse previamente estipuladas e com o critério de parada que será comentado em detalhes no item 2.6.2. Em seguimento, todo este processo foi refeito para cada imagem pertencente ao conjunto de recortes.

2.5.2.1 Análise espectral realizada

A análise espectral proposta por esta tese baseia-se nos pixels da imagem e nas suas relações de vizinhança, de forma a fornecer parâmetros às técnicas de IC, tal qual Gonçalves *et al.* (2008). Chamou-se de assinatura espectral tais quantizações presentes em cada uma das bandas do sensor e sua relação com os vizinhos mais próximos. O processo de extração da assinatura espectral proposta é apresentado na Figura 26.

A assinatura espectral de um pixel, assim proposta, será um vetor-linha cujos elementos são os níveis de quantização do pixel para cada uma das bandas e de tamanho igual ao número de bandas do sensor utilizado. Os valores de cada elemento deste vetor-linha serão números inteiros naturais. Logo, para esta tese, a assinatura espectral dos pixels terá a seguinte conformação:

$$[b_1, b_2, b_3, b_4, b_5, b_7] \quad (1)$$

onde: $b_n = [0, 256], \forall b_n \in \mathbb{N}; e$

$n =$ o número de bandas utilizadas do LANDSAT-5;

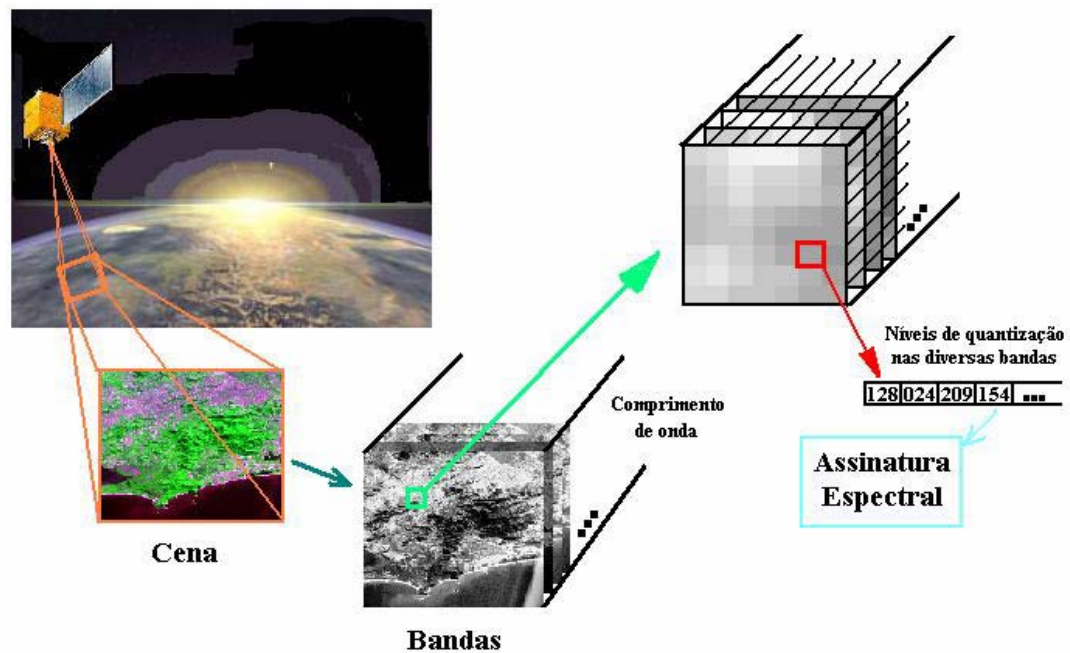


Figura 26 - Processo de extração de assinatura espectral proposta (adaptada TEIXEIRA, 2010, p. 386).

Como exemplo da assinatura espectral proposta acima, dentre os pixels inequívocos escolhidos pela especialista em imagem para a classe Área Construída, apresenta-se o pixel de número 12 (área urbana perto da Praia de Icaraí, na cidade de Niterói: coluna 5180 e linha 2660 da cena), dentre os 30 escolhidos, que possui a seguinte conformação: P12 ac = [54, 23, 22, 29, 40, 22].

Além dos pixels da assinatura, estipulou-se a entrada de seus pixels mais próximos, de forma a se construir uma máscara de pixels, que fornece mais subsídios para as técnicas de IC. Esta máscara é de conformação 3x3, utilizando os oito vizinhos mais próximos do pixel em estudo. Na Figura 27 é apresentado um exemplo de máscara de pixels 3x3 da classe Manguezal (cor esverdeada). A utilização dos pixels vizinhos mais próximos nesta integração é ressaltada por Alves (2004):

Existem restrições nos programas de classificação automática de imagens, principalmente no caso de algoritmos que examinam cada elemento da imagem (pixel), de forma independente dos demais vizinhos, e que tendem a produzir resultados estatisticamente significativos, mas espacialmente incoerentes (ALVES, 2004, p. 34).




Figura 27 - Exemplo de máscara 3x3 dos vizinhos mais próximos de um pixel da classe Manguezal.

Como descrito no item 2.2.1, foi estabelecido pela especialista em imagem um conjunto de 30 pixels inequívocos para cada uma das classes (cinco mais a classe Sedimento, presente somente no recorte 1A) de interesse constantes na cena em análise, perfazendo um total de 180 pixels selecionados em toda cena (Figura 23). Como cada pixel inequívoco possui seis quantizações diferentes (uma para cada banda do sensor utilizado), obteve-se um conjunto de 1.080 quantizações selecionadas para cada classe, sendo este conjunto chamado de conjunto de treinamento P (pixels), que são efetivamente as assinaturas inequívocas de cada classe analisada.

Além disso, cada pixel inequívoco também possui uma associação com oito pixels vizinhos imediatamente adjacentes (Figura 28), ficando cada pixel inequívoco associado a um total de 54 quantizações, sendo que cada classe (com 30 pixels inequívocos) possui um total de 1.620 quantizações selecionadas, o que gera um total de 9.720 quantizações (para as seis classes) chamadas de conjunto de treinamento V (de vizinhos). Foram realizadas inferências estatísticas simples tanto no conjunto de treinamento P quanto no V, que serão explicitadas no item 2.6.1.1.

Ressalta-se que a análise espectral (tanto a assinatura, quanto a máscara de pixels) realizada foi baseada inteiramente na observação do trabalho de análise e interpretação visual realizada pela especialista em imagem em cena de satélite multiespectral.

2.6 Implementação e teste do integrador

Além dos sistemas computacionais IDRISI e ENVI já mencionados, foram utilizados os sistemas MARLIN, GIMP 2.7.0 (GNU *Image Manipulation Program*), e MATLAB – *MATrix LABoratory* (MATLAB, 2010), versão R2010a, sendo o primeiro utilizado na análise da imagem pela especialista, o segundo para colorização das saídas do integrador e o terceiro para implementação e teste dos algoritmos. O MARLIN e o GIMP são programas gratuitos e disponíveis na *Internet* para baixar em INPE (2009) e em GIMP (2009).

Os módulos MRNC, MLD e MTD do integrador proposto foram implementados no MATLAB, sendo cada módulo da integração proposta correspondente a um algoritmo. Foi utilizado o programa *Microsoft Office Excel*, versão 2007, da companhia *Microsoft*, que é uma planilha eletrônica com ferramentas de cálculo, para uso na análise espectral: o BAE foi implementado no programa *Excel*: os dados – conjuntos de treinamento P (assinaturas) e V – foram importados para os algoritmos do MATLAB, quando requisitados.

Os recursos computacionais, isto é, o equipamento (*hardware*) utilizado para o teste da integração proposta é bem simples: um computador com processador de quatro núcleos de 2GHz, com 4GB de memória RAM (*Random Access Memory*), placa de vídeo de 1GB, com HD (*Hard Disc*) de 500GB de capacidade e gravador de DVD-ROM. Atualmente, esta é uma máquina que pode ser encontrada facilmente na grande maioria das lojas de informática, com preço bem acessível – inferior a três salários-mínimos. Desta forma, pretende-se caracterizar que a integração não irá demandar recursos computacionais caros ou específicos, podendo ser utilizada por qualquer pessoa com um computador plenamente disponível no comércio local.

2.6.1 Implementação do integrador

A Figura 28 apresenta o fluxograma do trabalho de implementação do integrador, sendo possível a visualização de todo o fluxo do trabalho realizado. O fluxograma do bloco do integrador é composto pelo esquema apresentado anteriormente na Figura 25. O fluxograma do bloco de teste do integrador é apresentado na Figura 36.

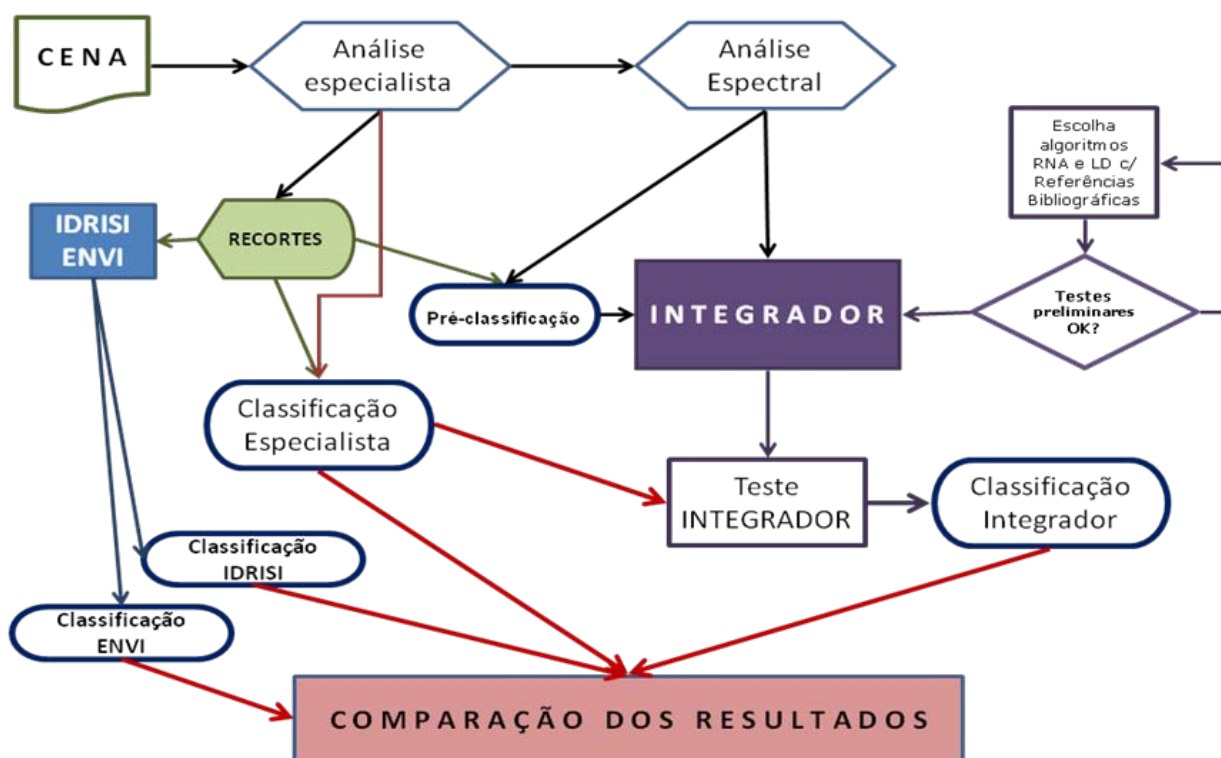


Figura 28 - Fluxograma de trabalho para implementação do integrador.

Antes da entrada no integrador, foi realizada uma pré-classificação – segmentação: agrupamento de mais de um pixel (GONZALES; WOODS, 2000) – em simples algoritmo implementado em MATLAB, de cada um dos três recortes, com base nos parâmetros estipulados para variação das assinaturas espectrais de cada uma das classes analisadas pela especialista, resultantes da análise espectral realizada e implementada no BAE (item 2.6.1.1). Assim, foram classificados somente os pixels de cada recorte que se adequaram a estes parâmetros, sendo: 9% dos pixels do recorte 1A, 7% do recorte 1B e 12% do recorte 1C. Estes pixels foram verificados, um a um, pela especialista, sendo constatado que eles estavam corretamente classificados. Estes pixels e suas correspondentes classificações foram armazenados para utilização no MTD.

Com base nos trabalhos citados no item 1.3 sobre as técnicas de RNC e LD, foram escolhidos os algoritmos SOFM e Mamdani para os respectivos módulos de MRNC e MLD. Antes da implementação do integrador, foram realizados testes preliminares destes dois algoritmos com quatro classes (Água, Área Construída, Florestal e Manguezal) para o primeiro recorte (1A – Guaratiba), como pode ser observado em Teixeira (2010), com a aplicação de regras bem simples. Como os resultados encontrados, em comparação com a classificação da especialista, ficaram com classificação média acima de 70% (TEIXEIRA, 2010), os algoritmos foram aceitos para implementação final.

As classificações de cada módulo são apresentadas em formato tipo Bitmap (BMP), com somente seis quantizações de pixel, isto é, em tons de cinza, onde: um significa a classe Água não Particulada; 30 significando a classe Água Particulada; 90 a classe Florestal; 140 a classe Manguezal; 180 a classe Área Construída; 254 a classe Outros. Observa-se que no primeiro recorte, por ter sido mantida a classe Sedimento, as classificações possuem sete quantizações de pixel, sendo o da classe Sedimento igual a 225. Posteriormente, quando da classificação final de cada recorte, foi realizada a colorização da imagem de acordo com o exposto no item 2.2.

2.6.1.1 Banco de Assinaturas Espaciais (BAE)

O BAE foi implementado no programa *Excel* com os dados dos conjuntos de treinamento P e V extraídos na análise espectral efetuada pela especialista, como descrito no item 2.5.2.1. Com base no conjunto de treinamento P (assinaturas espectrais inequívocas) e no V de cada classe a especialista realizou inferências estatísticas, trabalhando com as funções de mínimo, de máximo, de média, de desvio padrão e de desvio padrão pela média para o levantamento dos parâmetros definidores de variação dos níveis de quantização de cada classe para cada banda do sensor.

Os parâmetros advindos do conjunto de treinamento P foram os utilizados na pré-classificação dos pixels de cada um dos recortes antes da entrada no integrador, sendo um exemplo a classe Água não Particulada, onde o parâmetro definidor para a classificação dos pixels pertencerem a esta classe foi o de possuir assinatura espectral com a seguinte conformação: [49 a 52; 15 a 18; 8 a 10; 3 a 6; 6 a 8; 2 a 4]. Esta conformação apresenta um desvio padrão menor que 2% em relação à média dos 30 pixels inequívocos para cada uma das seis bandas analisadas: este mesmo valor de desvio padrão foi aplicado para as demais conformações de assinatura espectral das outras classes na pré-classificação.

Como exemplo, a Figura 29 apresenta um exemplo da tela do *Excel* com as inferências estatísticas realizadas para todas as classes, com destaque da guia em aberto para a classe Florestal.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
1	Análise dos valores espectrais das classes em estudo da cena 017/076 do LANDSAT														
2	Local	Pixel	Coluna	Linha	5b1	5b2	5b3	5b4	5b5	5b7	1b1	1b2	1b3	1b4	1b5
3	Floresta da Tijuca	p23	4803	2829	35	15	12	63	37	9	44	19	8	68	57
4	Floresta da Tijuca	p24	4527	2857	30	13	11	54	33	12	39	12	13	62	61
5	Floresta da Tijuca	p25	4586	2832	37	18	12	64	37	13	42	11	15	64	56
6	Floresta da Tijuca	p26	4624	2923	42	13	12	56	28	6	38	22	9	66	59
7	Maciço do Mendanha	p27	4030	2769	38	14	15	60	41	14	44	17	17	55	55
8	Maciço do Mendanha	p28	3880	2748	40	20	10	55	39	7	41	15	5	43	49
9	Maciço do Mendanha	p29	3837	2812	41	16	12	59	30	6	33	19	11	51	50
10	Maciço do Mendanha	p30	3798	2855	38	18	9	54	35	10	61	11	14	50	53
11		Mínimo			30	13	9	54	28	6	33	11	5	43	49
12		Máximo			42	20	15	64	41	14	61	22	17	68	61
13		Média			37,625	15,875	11,625	58,125	35	9,625	42,75	15,75	11,5	57,375	55
14		Desvio Padrão			3,8149	2,5877	1,7678	3,9799	4,4401	3,1595	8,2071	4,1662	4	8,9433	4,1748
15		Desv/ Média			0,1014	0,163	0,1521	0,0685	0,1269	0,3283	0,192	0,2645	0,3478	0,1559	0,0759
16		Média dos desvios padrões dos pixels principais	3,291636												
17		Média dos desvios padrões dos pixels vizinhos	11,38518												
18															
19															

Figura 29 - Banco de Assinaturas Espectrais (BAE) implementado no *Excel*, com parte da classe Florestal na guia aberta.

Ressalta-se que todos os pixels do conjunto P (ressaltado na cor rosa) de todas as classes apresentaram desvio padrão médio inferior a 5%, enquanto que para todos os pixels do conjunto V o desvio padrão médio foi inferior a 15%. Estes valores guiaram a feitura de conformações de assinatura espectral com desvio padrão inferior a 5%, a 10% e a 15% para cada classe, essenciais para a definição das classes no MTD.

2.6.1.2 Módulo de Redes Neurais Computacionais (MRNC)

O MRNC foi implementado no algoritmo SOFM (*Self-Organizing Feature Maps*) do MATLAB (Figura 30 e 31), com a entrada de todos os valores dos pixels presentes em cada uma das seis bandas das imagens teste em uma única matriz. Foi utilizada a topologia retangular (função *gridtop*) – arranjo dos neurônios da rede – com diâmetro 1, e com a função euclidiana de distância (*dist*) para a distância entre os neurônios. A rede foi formada com 36 neurônios com conformação 6 X 6.

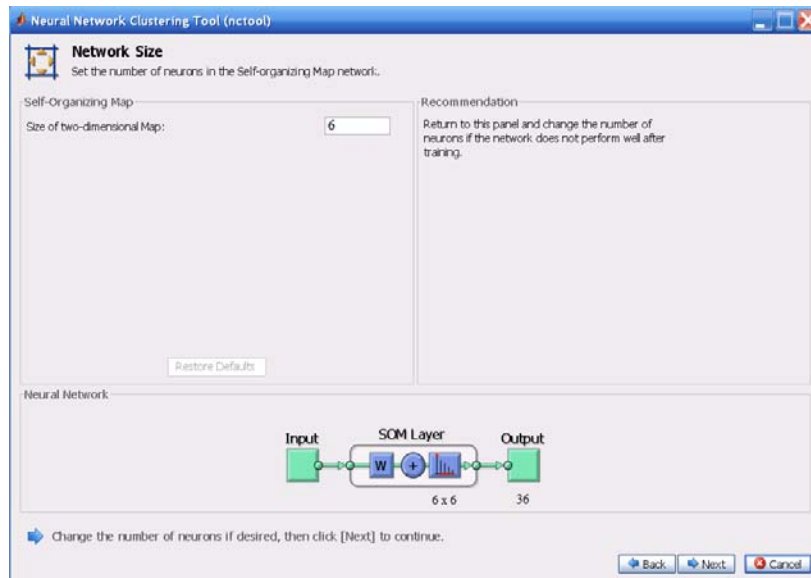


Figura 30 - Tela do MATLAB utilizada para a geração do MRNC com a topologia.

A entrada do MLD consiste de uma matriz com todos os valores dos pixels presentes em cada uma das bandas da imagem analisada (recortes 1A, 1B e 1C). Desta forma, têm-se seis “imagens” do recorte em análise que foram transformadas em uma única matriz de entrada, onde cada linha desta matriz corresponde a um pixel específico da imagem, com cada coluna representando uma das bandas utilizadas.

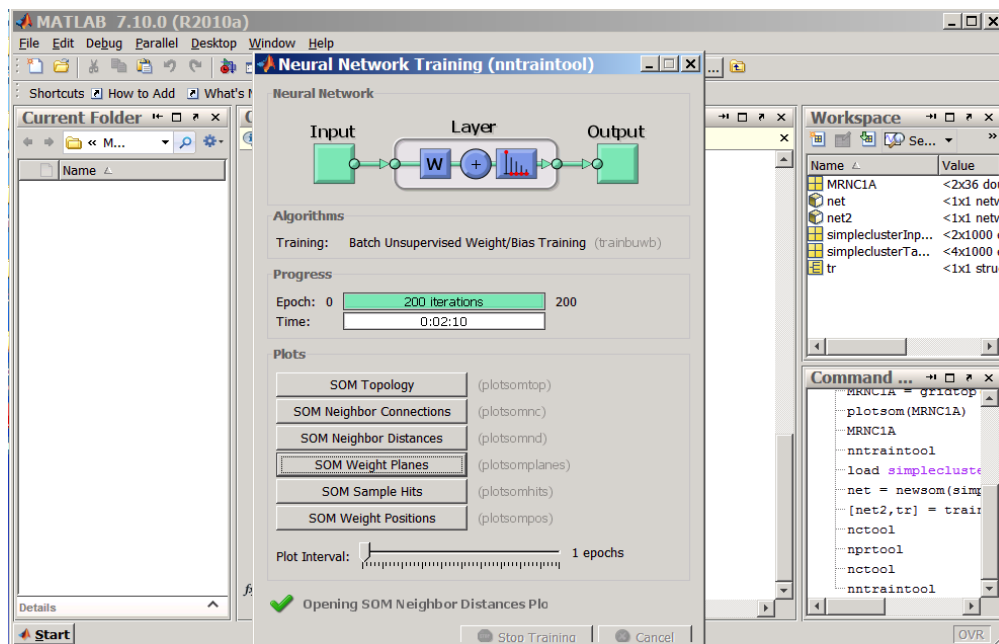


Figura 31 - Tela do MATLAB com o treinamento da rede.

2.6.1.3 Módulo de Lógica Difusa (MLD)

O MLD foi implementado através da utilização do algoritmo Mamdani de inferência *fuzzy* (Mamdani, 1975), do módulo *Fuzzy* do MATLAB, com o método do menor dos máximos para a etapa de “defuzzificação”, devido aos testes já realizados por Teixeira (2004) e Noguchi (2004), além de ser intuitivo, de ter aceitação pela comunidade científica e de ser o melhor para a entrada de dados de especialistas (MATLAB, 2010). A entrada do MLD, como mostrada na Figura 32, consiste de uma matriz com todos os valores dos pixels presentes em cada uma das bandas da imagem analisada (recortes 1A, 1B e 1C). Desta forma, têm-se seis “imagens” do recorte em análise que foram transformadas em uma única matriz de entrada, onde cada linha desta matriz corresponde a um pixel específico da imagem, com cada coluna representando uma das bandas utilizadas.

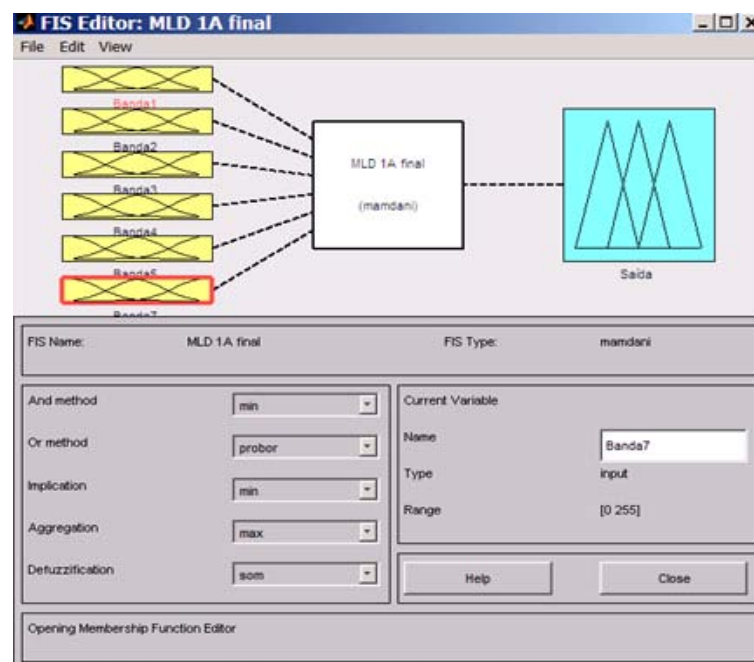


Figura 32 - MLD implementado no MATLAB.

As regras de entrada do MLD (a “fuzzificação” das entradas) foram implementadas segundo os conjuntos definidores das classes (conjuntos de treinamento V contidos no BAE), com base nos conhecimentos da especialista de imagem. Desta forma, cada classe foi representada por seis funções de pertinência (específicas para cada uma das bandas do LANDSAT utilizadas). Na Figura 33 são mostradas estas funções para a banda 4.

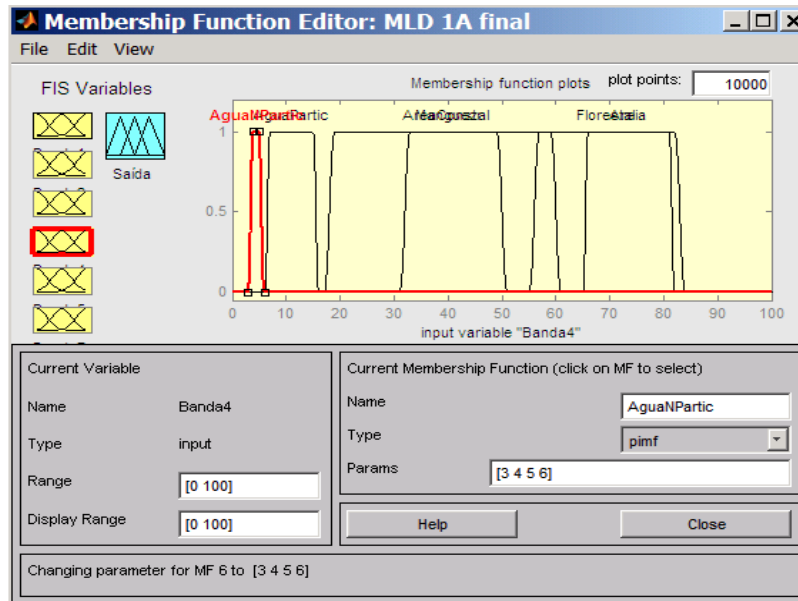


Figura 33 - Tela do MLD com as funções de pertinência da banda 4, com o detalhe para os parâmetros da função água não particulada.

O conjunto de regras do MLD apresenta seis regras (uma para cada classe), sendo que quando não houver atendimento de nenhuma das regras, o resultado de classificação daquele pixel será a classe Outros (Classe Fora do Interesse – CFI). O conjunto de regras otimizado para o recorte 1A – Guaratiba (que possui a classe Sedimento) foi o seguinte (para os outros dois recortes foram utilizadas somente as cinco primeiras regras):

1. IF (BANDA2 is AguaNPartic) AND (BANDA4 is AguaNPartic) AND (Banda5 is AguaNPartic) THEN (Saída is AguaNPartic);
2. IF (BANDA1 is AguaPartic) AND (BANDA4 is AguaPartic) AND (BANDA5 is AguaPartic) THEN (Saida is Agua Partic);
3. IF (BANDA1 is AreaConstr) AND (BANDA3 is AreaConstr) AND (BANDA4 is AreaConstr) AND (BANDA7 is AreaConstr) THEN (Saida is AreaConstr);
4. IF (BANDA1 is Florestal) AND (BANDA3 is Florestal) AND (BANDA4 is Florestal) AND (BANDA5 is Florestal) THEN (Saida is Florestal);
5. IF (BANDA3 is Manguezal) AND (BANDA4 is Florestal) AND (BANDA5 is Florestal) THEN (Saida is Florestal); e
6. IF (BANDA 2 is Sedimento) AND (BANDA4 is Sedimento) AND (BANDA7 is Sedimento) THEN (Saida is Sedimento).

Este conjunto de regras permitiu a geração da imagem classificada em quatro minutos, em média (para o hardware utilizado, como apresentado no item 2.6). A Figura 34 apresenta a tela da função de saída para o recorte 1A (para os outros dois recortes a função não apresenta a classe Sedimento).

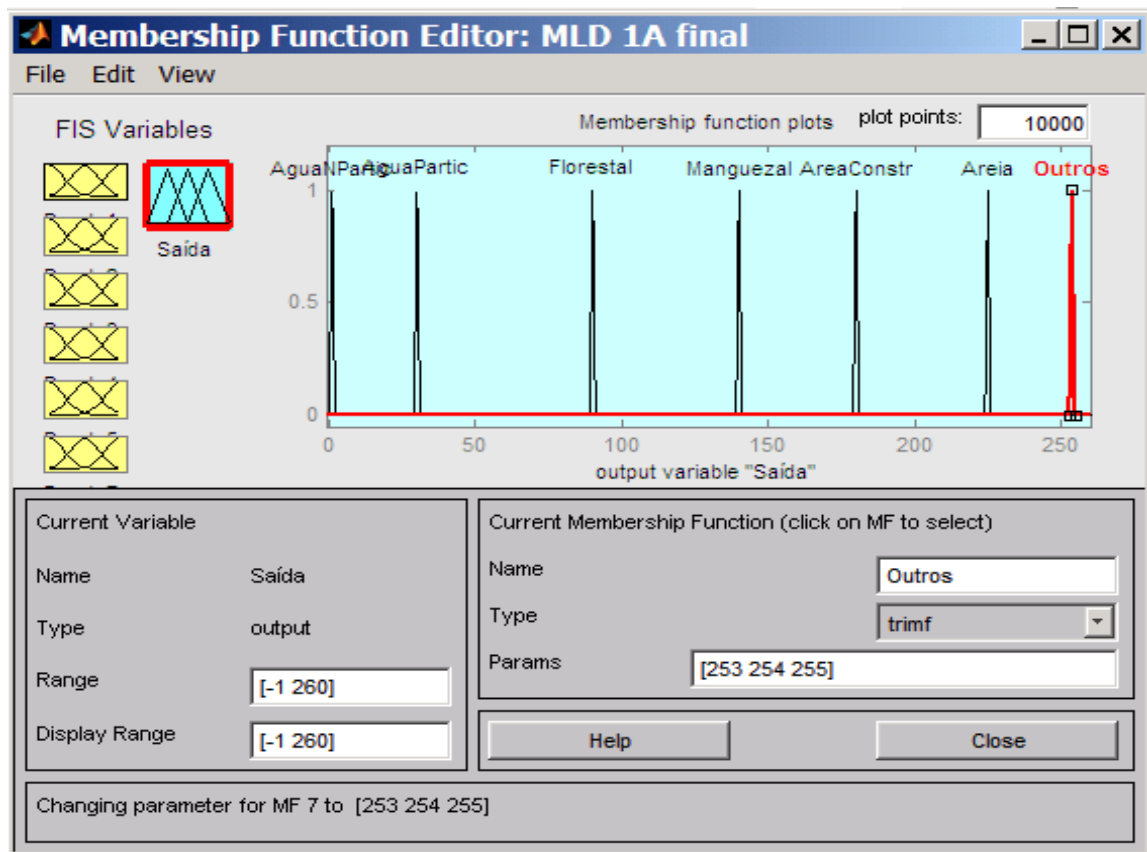


Figura 34 - Tela da função de saída do MLD implementado.

2.6.1.4 Módulo Tomador de Decisão (MTD)

O MTD foi implementado com regras baseadas nos pixels pré-classificados e sua relação de vizinhança com as discrepâncias e concordâncias observadas entre as classificações dos MRNC e MLD, com o suporte da especialista em imagem. A saída deste módulo apresenta uma imagem classificada e um relatório estatístico com as discrepâncias e concordâncias encontradas entre os módulos MRNC e MLD.

A entrada do MTD, cujo esquema é mostrado na Figura 35, é composta pelas classificações resultantes dos MRNC e MLD. Com a implementação de um algoritmo simples, em MATLAB, de análise pixel-a-pixel, é verificado se o mesmo pixel nas duas classificações possui concordância de classe. Se não houver concordância são requisitadas as

conformações de assinaturas espectrais de cada classe dos módulos, armazenadas no BAE, com desvio padrão inferior a 2%, a 5%, 10% e a 15% para comparação com a assinatura espectral do pixel em análise. A classe ganhadora será aquela com a conformação da assinatura espectral mais próxima a do pixel. Em caso de um dos módulos ter classificado o pixel na classe Outros (CFI), o algoritmo irá verificar somente se a outra classe possui conformação próxima (2%, 5%, 10% ou 15%) a da assinatura do pixel.

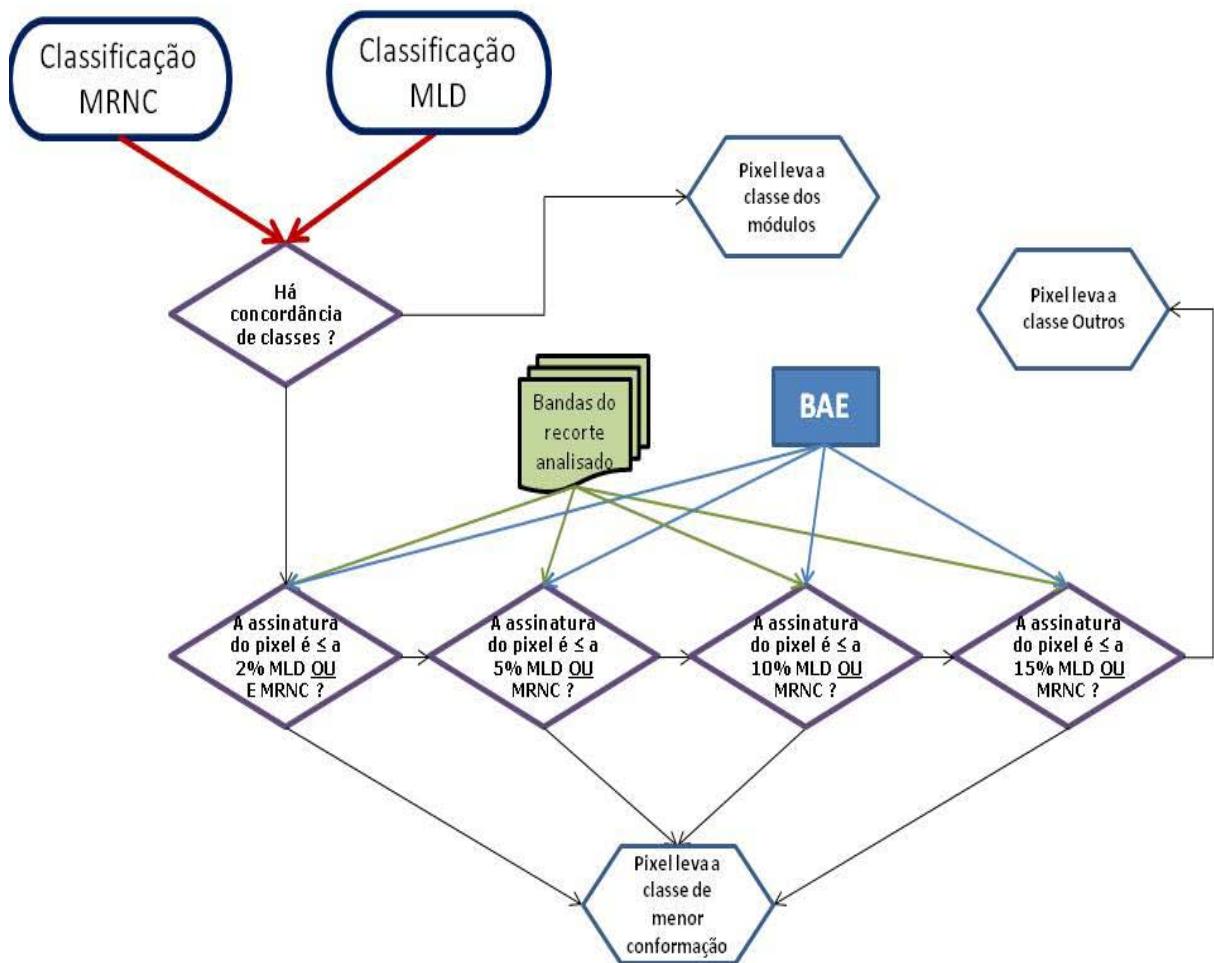


Figura 35 - Esquema de trabalho do algoritmo do MTD.

Observa-se que caso a conformação da assinatura do pixel esteja acima de 15%, este será classificado como Outros, mesmo que esta não tenha sido a classe escolhida pelos dois módulos.

2.6.2 Teste do integrador

O fluxograma dos testes com o integrador é apresentado na Figura 36.

O critério de parada de fases de ajustes dos parâmetros dos módulos do integrador (MRNC, do MLD e do MTD), com consequente reclassificação, foi o índice de acerto médio das classes ser maior ou igual a 85% e o índice de acerto de cada classe ser maior ou igual a 75%, em relação às classificações realizadas pela especialista de imagem.

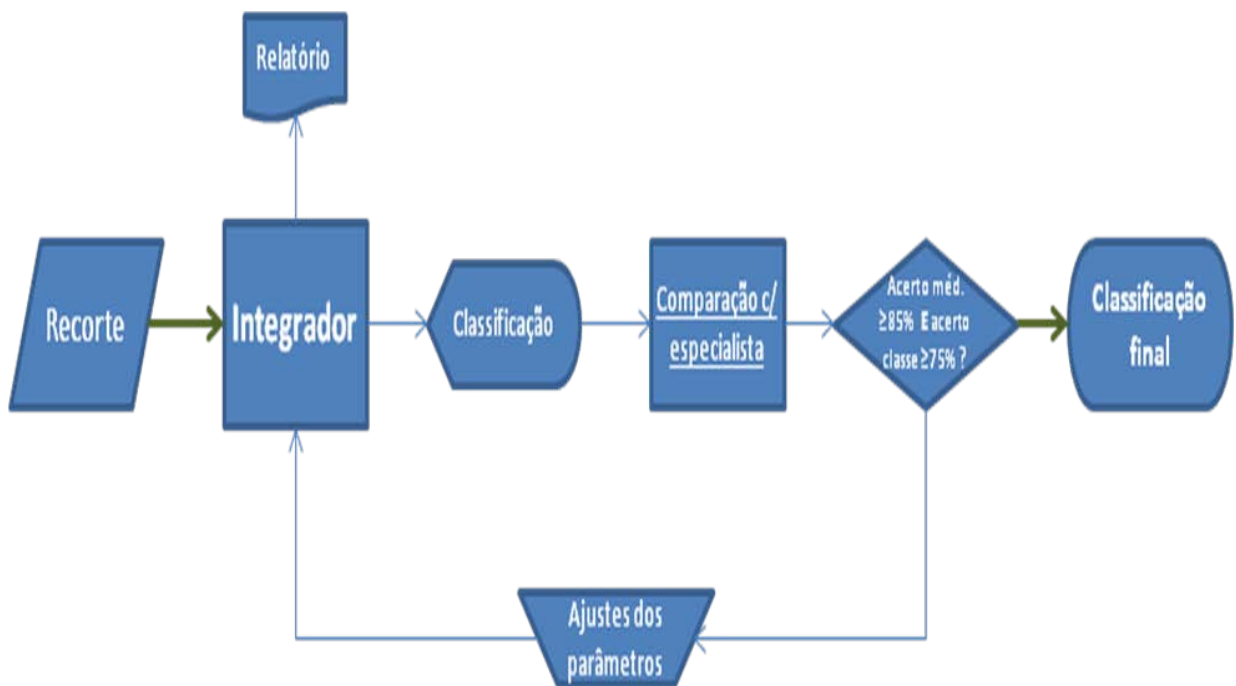


Figura 36 - Fluxograma dos testes do integrador.

A classificação do recorte 1A (Guaratiba) pelo integrador necessitou de 21 fases de ajustes e, conseqüentemente, 21 reclassificações até que o resultado da classificação obedecesse ao critério de parada. Para a classificação do recorte 1B (Mangaratiba), houve a necessidade de 13 fases de ajustes e, conseqüentemente, 13 reclassificações. O recorte 1C (Magé) requereu nove fases de ajustes com conseqüentes nove reclassificações.

2.6.3 Avaliação das classificações

Para o adequado teste e comprovação da eficácia da integração proposta, além da confrontação dos resultados obtidos na integração frente aos conhecimentos adquiridos por

especialista em imagens com larga experiência, optou-se também pela comparação dos resultados obtidos (desempenho), em relação a tempo de processamento computacional e quantificação dos resultados (assertiva das classes de interesse), em relação àqueles alcançados pelos sistemas computacionais IDRISI e ENVI, que se apresentam dentro do grupo de sistemas de mais largo emprego no Processamento de Imagens advindas de Sensoriamento Remoto orbital, visto que estes traduzem o atual estado da arte.

Esta padronização será apresentada através da apresentação de um quadro comparativo onde são comparadas todas as classificações, e de forma a padronizar a análise das classificações obtidas pelo integrador e pelos sistemas computacionais IDRISI e ENVI, frente aos conhecimentos adquiridos por especialista em imagens, foi estipulado que as classes serão avaliadas em relação aos seguintes parâmetros:

- não delineada = ndl (igual ou menos de 40%);
- medianamente delineada = mdl (entre 40% e 75%);
- bem delineada = bdl (igual ou maior que 75%);
- sest = superestimada (a classe abarca área na imagem igual ou maior que 30% que a análise da especialista);
- sdi = sem distinção (ocorre quando a classe não pode ser analisada pois houve confusão com mais de duas classes);
- trXXX (sendo XXX = sigla da classe) : traços (igual ou menos de 30%) de outra classe presente; e
- cf/XXX (sendo XXX = sigla da classe): confusão (igual ou maior de 30%) com outra classe.

A fim de avaliar a acurácia das classificações analisadas, utilizou-se o índice Kappa (k). Kappa é uma medida de concordância interobservador, medindo o grau de concordância além do que seria esperado tão somente pelo acaso.

O trabalho de Gong e Howarth (1990) utilizou o índice Kappa como uma medida de precisão importante, pois a matriz de erro associada é representada inteiramente, com a consideração de todos os elementos da matriz e não apenas aqueles que se situam na diagonal principal, como o que ocorre com o índice de Exatidão Global (daí o porquê deste índice alcançar valores tão altos). Ocorre que Foody (1992) ressalta que tal grau de concordância, por chance, poderia estar sendo superestimado, já que ele inclui também a concordância real. Tal fato ocasionou o surgimento do índice Tau, como escrito por Ma e Redmond (1995) em seu trabalho sobre o coeficiente Tau ser índice de acurácia válido para classificação em dados advindos de sensoriamento remoto.

Figueiredo e Vieira (2007) fizeram um estudo do comportamento dos índices de Exatidão Global, do Kappa e do Tau, que são os mais comuns na avaliação de classificação de imagens. Este estudo demonstrou que os coeficientes de concordância dos índices Kappa e Tau são mais consistentes que a Exatidão Global, e que a diferença entre os índices Kappa e Tau é muito pequena, de forma que a utilização do Kappa para validar classificações de imagens é aceitável.

O trabalho de Bolfe *et al.* (2003) também atesta a consistência entre os índices Kappa e Tau para a classificação de três classes de florestas, ressaltando que o índice Kappa e Tau sempre serão menores o de Exatidão Global pois estes sempre consideram todas as células da matriz de erros (daí serem mais consistentes).

O Quadro 3 apresenta a avaliação da qualidade de classificações pelo índice Kappa proposta por Landis e Koch (1977) e por Foody (1992, 2002). Apesar destes valores e respectivas qualidades, Foody (2002) sugere que o índice Kappa representativo de uma boa classificação deve se situar de 0,85 para cima.

Índice Kappa	Qualidade da Interpretação
≤ 0	Péssima
0,01 a 0,20	Ruim
0,21 a 0,40	Razoável
0,41 a 0,60	Boa
0,61 a 0,80	Muito Boa
0,81 a 1,00	Excelente

Quadro 3 - Qualidade da classificação analisada associada aos valores do índice Kappa (LANDIS; KOCH, 1977).

Para a realização do índice Kappa foram selecionados, sendo bem distribuídos por cada um dos três recortes da área-teste, 90 pontos amostrais (pontos de controle) para o recorte 1A e 75 pontos para os outros dois recortes (1B e 1C) – 15 pontos para cada classe, inclusive a classe Outros (CFI) – sendo estes pontos plenamente discerníveis tanto na imagem como em cartas do terreno, já que os padrões de cobertura e ocupação nestas regiões são bastante conhecidos pela especialista. Os pontos são mostrados na Figura 37. Tais pontos foram selecionados com base em cartas da região, classificações e programas de visualização de terreno *online* (*Google earth*) que permitiram a identificação inequívoca destes pontos sem a necessidade de ida a campo, o que iria despender muito tempo devido a grande área de cada um dos recortes (de 600 a 1.050 km²).

O índice Kappa foi obtido através do sistema IDRISI Taiga com a sobreposição destes pontos sobre as classificações. Após a criação do arquivo vetorial dos pontos de controle (módulo *Sample*) foram anotados os indicadores de cada classe correta do uso do solo e na sequência este arquivo foi salvo em formato avl (arquivo de valores) no módulo *Edit*. O arquivo vetor dos pontos juntamente com o arquivo de valores foram inseridos no módulo *Assign*, para então associar os indicadores corretos do uso do solo ao arquivo vetorial de pontos de amostragem. No módulo ERRMAT, pelo cruzamento do arquivo gerado na função ASSIGN com a classificação supervisionada, o índice Kappa foi gerado.




Figura 37 - Os pontos de controle em cada recorte: (a) 1A – Guaratiba (90 pontos); (b) 1B – Mangaratiba (75 pontos); e (c) 1C – Magé (75 pontos).

Por fim, as classificações também foram avaliadas em termos de tempo despendido para o processamento da classificação.

3 RESULTADOS

A seguir serão expostas as classificações obtidas pelo integrador, as classificações dos sistemas IDRISI e ENVI, e as da especialista em imagem.

Para melhor comparação, o Quadro 4 apresenta a padronização de cores (explicitada no item 2.2) utilizadas em todas as classificações tanto do integrador e da especialista, como nos sistemas computacionais analisados.

CLASSE	COR
Água Particulada	Marrom
Água não Particulada	Azul
Área Construída	Vermelha
Florestal	Verde
Manguezal	Amarela
Sedimento *	Branca
Outros (CFI)	Preta

* Classe presente somente no recorte 1A – Guaratiba.

Quadro 4 - Tabela de cores para as classificações analisadas.

Ressalta-se que as classes de interesse e, respectivamente, as classificações realizadas, tanto pela especialista, quanto pelos programas IDRISI e ENVI, e pelo integrador, são relativas somente à cobertura e ocupação da terra ou solo, não sendo levantadas questões quanto à sua utilização (uso da terra).

As classificações da especialista em imagem são apresentadas em tamanho maior no Apêndice A (p. 127). O mesmo ocorre para as classificações do IDRISI Taiga no Apêndice B (p. 129), as classificações do ENVI no Apêndice C (p. 132) e as do integrador no Apêndice D (p. 135).

3.1 Avaliação visual das classificações dos sistemas IDRISI e ENVI *versus* classificações da especialista *versus* integrador

De modo a poder comparar melhor os resultados, as classificações de cada recorte foram agrupadas em uma figura com a seguinte ordem de apresentação: (a) a classificação da especialista; (b) a classificação escolhida como a melhor do sistema IDRISI Taiga para o

recorte; (c) a classificação escolhida como a melhor do sistema ENVI para a área; e (d) a classificação do integrador. Desta forma todas as classificações puderam ser comparadas em uma única figura, fornecendo uma visualização total das quatro classificações para a melhor compreensão dos quadros comparativos das classificações, cujas legendas de comparação foram explicitadas no item 2.6.3..

As funções ISODATA e K-MEANS do sistema computacional ENVI resultaram em classificações bem similares como alertado por ENVI (2011) e por Ohata e Quintanilha (2005). As classificações obtidas pela função K-MEANS podem ser observadas no Apêndice C.

As funções ISOCLUST do IDRISI e ISODATA do ENVI foram as escolhidas para comparação de resultados devido aos melhores resultados apresentados.

3.1.1 Recorte 1A – Guaratiba

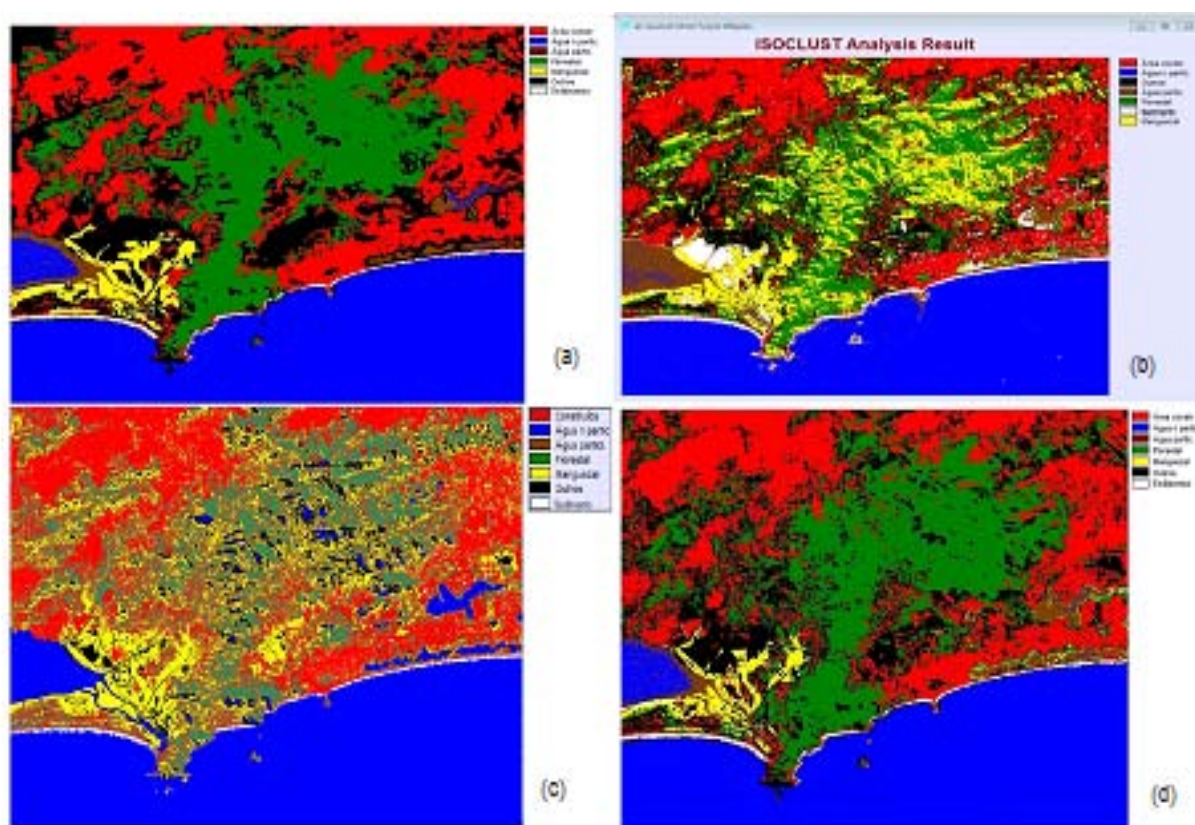


Figura 38 - Classificações do recorte 1A – Guaratiba: (a) da especialista; (b) do IDRISI (ISOCLUST); (c) do ENVI (ISODATA); e (d) do integrador.

O Quadro 5 e a Figura 38 proporcionam um melhor entendimento dos resultados encontrados para cada uma das classificações (item 2.6.2).

CLASSES	Integrador	Especialista	IDRISI Isoclust	ENVI Isodata
Água Partic. (AP)	bdl	bdl	mdl, trA	mdl, sest
Água n Part. (ANP)	bdl	bdl	bdl	cf, sdi
Área Contr. (AC)	mdl	bdl	bdl	bdl
Florestal (F)	bdl, trAC	bdl	ndl, cfMA	mdl, trMA, trAP, trANP
Manguezal (MA)	mdl	bdl	sest, cfF	sest
Sedimento (A)	bdl	bdl	mdl, sest	bdl
Outros – CFI (CF)	mdl, trAC	bdl	mdl, trA	ndl, trMA, trAP

(ndl=não delimitada; mdl=medianamente delimitada.; bdl=bem delimitada; sest=superestimada; sdi=sem distinção; trCLAS= traço de outra classe; cfCLAS=confusão c/ outra classe (item 2.6.3))

Quadro 5 - Quadro comparativo da análise das classificações realizadas pela especialista, pelos sistemas IDRISI e ENVI, e pelo integrador para o recorte 1A - Guaratiba.

Neste recorte a classificação ISOCLUST do IDRISI (Figura 39b) apresentou uma classificação boa tanto da classe Área Construída como da classe Água não Particulada (ficando os corpos de água bem destacados, inclusive os rios). A classe Sedimento foi medianamente delimitada, pois todo o litoral, onde existe esta classe, foi delimitado, mas houve classificações em excesso (superestimada) desta classe em outras áreas do recorte, como os apicuns do manguezal – estas áreas são aquelas pertencentes à classe Outros (CFI), caracterizando uma incorreção da classificação (como também aparece no meio de áreas urbanas – porções superiores direita e esquerda do recorte): houve três casos onde a classificação da Sedimento não foi adequada, pois foram inclusas em área pertencente a classe Água não Particulada (nas lagoas da Barra da Tijuca). A classe Água Particulada foi medianamente delimitada, pois foi superestimada na região da Baía de Sepetiba (Restinga de Marambaia). A classe Manguezal foi superestimada já que foi expandida para áreas da classe Florestal e esta não foi delimitada visto que apresenta menos de 40% de sua área classificada: o algoritmo confundiu estas classes. A classe Outros foi medianamente classificada e apresentou traços da classe Sedimento em locais de sua localização.

Na classificação ISODATA do ENVI (Figura 39c) a classe Água Particulada foi medianamente definida, uma vez que nos locais da classe particulada houve a classificação como não particulada (foi superestimada). A classe Água não Particulada apresenta alta confusão com locais de presença das classes Florestal, Manguezal e outros, não podendo ser distinta. A classe Florestal foi medianamente modelada, mas ficou aquém da classificação

real devido à classificação de áreas de Manguezal e de Água Particulada em locais da classe Florestal. A classe Manguezal foi superestimada, aparecendo em áreas da classe Florestal e da classe Outros. A classe Outros não foi delineada, pois a sua classificação ficou aquém de 30% do que deveria ser classificados, devido às classificações errôneas das classes Manguezal e Água Particulada. As classes Sedimento e Área Construída foram surpreendentemente bem delineadas.

A classificação resultante do integrador proposto para o recorte 1A – Guaratiba conseguiu um bom delineamento das classes Água não Particulada, Água Particulada (as lagoas da Barra foram classificadas corretamente como Água Particulada devido a salinidade, poluição presentes nas mesmas), Florestal (houve uma classificação de área Florestal errônea ao redor das lagoas na Barra da Tijuca) e Sedimento (esta classe, presente somente neste recorte, foi muito bem demarcada, com sua presença somente no litoral). A Área Construída foi razoavelmente classificada, pois houve a classificação destas áreas em locais da presença de área Florestal ou da classe Outros. A classe Manguezal foi medianamente delineada, pois não foi classificada em sua completude na região da Reserva Biológica Estadual de Guaratiba, já que a classe Florestal foi alocada em parte desta classe erroneamente. A classe Outros foi medianamente delineada apresentando traços da classe Área Construída.

3.1.2 Recorte 1B – Mangaratiba

CLASSES	Integrador	Especialista	IDRISI Isoclust	ENVI Isodata
Água Partic. (AP)	bdl	bdl	mdl, sest	sdi
Água n Part. (ANP)	bdl	bdl	bdl	bdl
Área Contr. (AC)	mdl	bdl	mdl, sest, trAP	ndl
Florestal (F)	bdl	bdl	mdl, cfMA	ndl
Manguezal (MA)	mdl	bdl	sdi	sest, cfF, cfCF, cfAC
Outros – CFI (CF)	mdl	bdl	sdi, cfMA, trAP, trAC	sdi

(ndl=não delineada; mdl=medianamente delineada.; bdl=bem delineada; sest=superestimada; sdi=sem distinção; trCLAS= traço de outra classe; cfCLAS=confusão c/ outra classe (item 2.6.3))

Quadro 6 - Quadro comparativo da análise das classificações realizadas pela especialista, pelos sistemas IDRISI e ENVI, e pelo integrador para o recorte 1B - Mangaratiba.

O Quadro 6 e a Figura 39 apresentam as comparações das classificações realizadas para o recorte 1B – Mangaratiba.




Figura 39 - Classificações do recorte 1B – Mangaratiba : (a) da especialista; (b) do IDRISI (ISOCLUST); (c) do ENVI (ISODATA); e (d) do integrador.

A classificação da função ISOCLUST do sistema IDRISI apresenta a classe Água Particulada medianamente delineada na baía, mas superestimada, pois esta se estende por várias porções do terreno, ocupando a classe Área Construída e outros, enquanto que a classe Água não Particulada apresenta um bom delineamento. A classe Área Construída foi razoavelmente delineada, mas superestimada com a ocupação de várias porções da classe outros, a qual ficou sem delineamento, sendo classificada em áreas pertencentes a classe Manguezal. Já a classe Manguezal não foi delineada, pois a classificação do IDRISI colocou esta classe em terreno da classe Florestal (medianamente delineada, mas com confusão com a classe Manguezal).

Na classificação da função ISODATA do ENVI a classe Manguezal ocupou áreas das classes Florestal, Outros e Área Construída, causando confusão destas classes, além de apresentar uma superestimação. Logo, as classes Área Construída (ficou superestimada) e Florestal não puderam ser delineadas, apesar de serem parcialmente distintas em alguns trechos da classificação. Já as classes Outros e Água Particulada não apresentaram delineamento que pudesse ser distinto convenientemente. A classe Água não Particulada

apresentou um bom delineamento, apesar da presença de algumas classificações errôneas em terra.

A classificação do integrador apresentou um bom delineamento para as classes Água Particulada, Água não Particulada e Florestal. As classes Área Construída, Manguezal e outros foram medianamente delineadas.

3.1.3 Recorte 1C – Magé

A Figura 40 e o Quadro 7 apresentam as comparações realizadas para o recorte 1C – Magé.

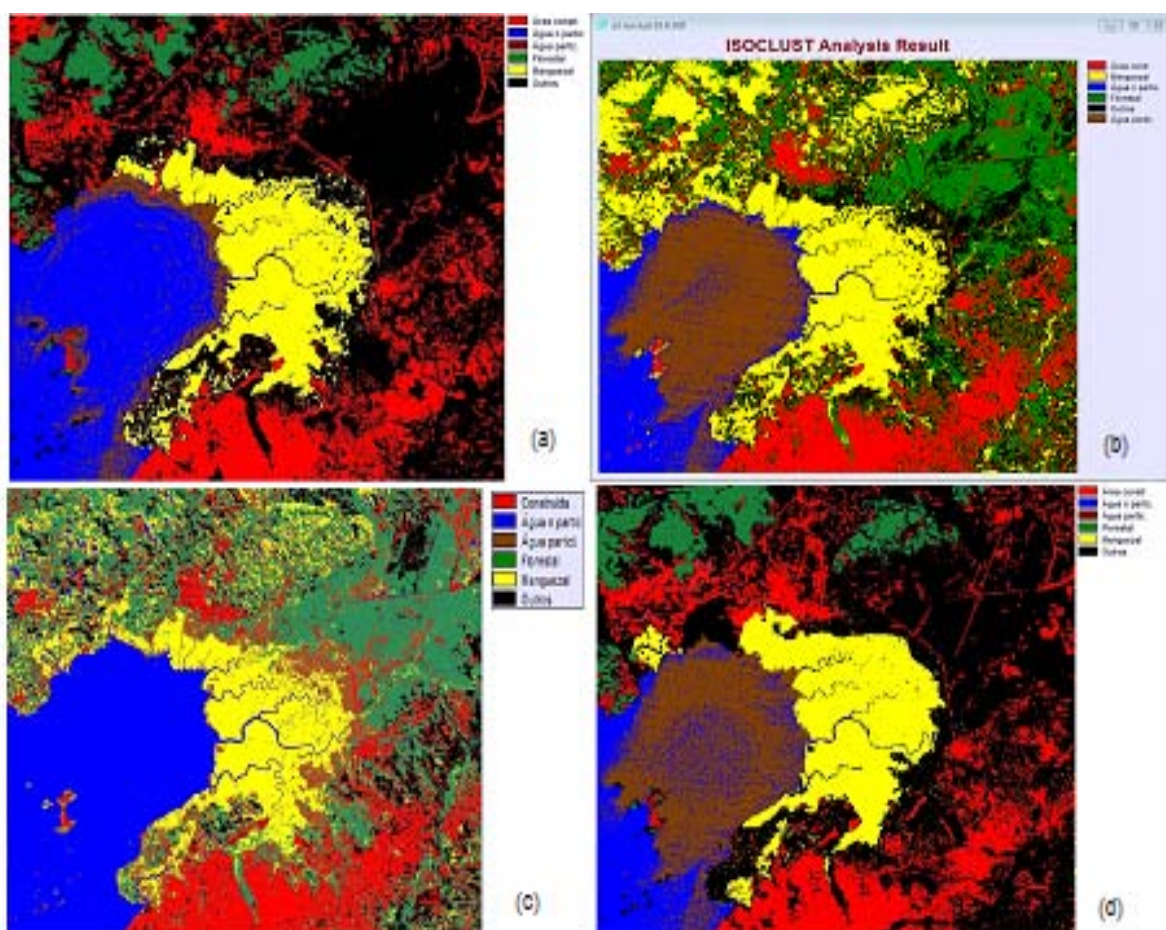


Figura 40 - Classificações do recorte 1C – Magé : (a) da especialista; (b) do IDRISI (ISOCLUST); (c) do ENVI (ISODATA); e (d) do integrador.

A classificação do integrador para as classes Área Construída, Florestal e outros apresentaram um bom delineamento, em relação a classificação da especialista. Já a classe Manguezal apresentou um delineamento razoável, pois houve um local erroneamente

classificado como Manguezal (deveria se a classe Outros) e outros três locais de Manguezal classificado como Outros. A classe de Água Particulada foi superestimada ocupando lugares da classe não particulada, o que levou a esta classe (não particulada) a ser razoavelmente delimitada.

A classificação da função ISOCLUST do IDRISI apresentou também uma super estimativa da classe Água Particulada. A classe Área Construída apresentou um mediano delimitamento (todos os locais desta classe não foram corretamente classificados, com a ocorrência de traços da classe Florestal). A classe Florestal não pode ser delimitada, pois menos de 30% foi corretamente classificada, já que houve confusão com locais da classe outros e da classe Manguezal: logo, a classe Manguezal foi superestimada. A classe Outros não foi delimitada devido a confusão com a classe Florestal, ficando sua classificação bem aquém do esperado.

Na classificação da função ISODATA do sistema ENVI, a classe Água Particulada foi classificada erroneamente em locais da presença das classes Manguezal, Outros, Florestal e Área Construída. A classe Água não Particulada foi medianamente delimitada, apesar de ter sido classificada em áreas de presença de Água Particulada (foi observada a presença desta classe em pequenos locais onde deveriam estar presentes as classes Florestal e Outros). A Área Construída foi medianamente delimitada, com a presença de traços da classe Água Particulada.

CLASSES	Integrador	Especialista	IDRISI Isoclust	ENVI Isodata
Água Particu. (AP)	sest	bdl	sest	sdi, cf
Água n Part. (ANP)	mdl, trAP	bdl	mdl, trAP	mdl
Área Contr. (AC)	bdl	bdl	mdl, trF	mdl, trAP, trMA
Florestal (F)	bdl	bdl	sdi, cfCF, trMA	sdi, cfCF, trAP, trMA
Manguezal (MA)	mbl	bdl	sest	sest, trAP
Outros – CFI (CF)	bdl	bdl	ndl, cfF	ndl, trAP

(ndl=não delimitada; mdl=medianamente delimitada.; bdl=bem delimitada; sest=superestimada; sdi=sem distinção; trCLAS= traço de outra classe; cfCLAS=confusão c/ outra classe (item 2.6.3))

Quadro 7 - Quadro comparativo da análise das classificações realizadas pela especialista, pelos sistemas IDRISI e ENVI, e pelo integrador para o recorte 1C – Magé.

A ISODATA do ENVI apresentou a classe Florestal “confusa” com a classe Outros (tal qual a função ISOCLUST do IDRISI) e traços das classes Água Particulada e Manguezal. A classe Manguezal foi superestimada, aparecendo em locais da classe Florestal e Outros. A

classe Outros não foi delineada, pois a maioria de suas áreas foram classificadas como pertencentes as classes Florestal e Manguezal.

Da análise dos três quadros comparativos (Quadros 5, 6 e 7) depreende-se que, no geral, os sistemas IDRISI e ENVI permitem um razoável delineamento das classes Água não Particulada e Área Construída, mas deve ser ressaltado que este delineamento só será bem compreendido por especialistas ou analistas de imagens: o usuário leigo não terá condições de realizar inferências corretas. No geral, as classificações destes sistemas apresentaram resultados inferiores as classificações da especialista e as do integrador, visto estes primeiros se utilizarem de algoritmos baseados em inferências estatísticas no pixel em si, sem considerar as relações de vizinhança, acarretando “resultados estatisticamente significativos, mas espacialmente incoerentes” como ressaltado por Alves (2004, p. 34). Como a ocorrência do pixel mistura é mais alta nas imagens do LANDSAT, a seleção dos pixels e seus respectivos vizinhos (que possuíssem alguns pixels mistura incorporados), aliados á lógica difusa, permitiu uma um maior acerto da integração proposta, tal qual relatado por Foody (1997), por Caimi (1993) e por Becerra e Bitencourt (2003).

Devem ser destacados dois pontos importantes observados no sistema ENVI: ele obteve um bom delineamento da classe Sedimento, presente somente no recorte 1A; e as classificações de ambas funções ISODATA e K-MEANS apresentaram um erro muito grande na análise da classe Água não Particulada, o que significa que apesar da inclusão de todas as seis bandas do LANDSAT (1 a 5 e 7), o ENVI não se utiliza da banda 2 na classificação, visto ser esta a que permite a sensibilidade à presença de sedimentos em suspensão (INPE, 2012).

Para os três recortes da área-teste, o integrador apresentou bom delineamento das classes Água Particulada, Água não Particulada, Sedimento e Florestal. O bom desempenho obtido na classe Água Particulada confirmou o estudo de Schroeter e Gliber (2011) quanto a utilização do LANDSAT, com o concurso do conhecimento de especialista em imagens para a correlação das assinaturas espectrais, para o monitoramento de poluição em lagos.

3.2 Avaliação das classificações dos sistemas IDRISI e ENVI *versus* classificações da especialista *versus* integrador segundo o índice Kappa e tempo de processamento

Como explicitado no item 2.6.3, foram calculados os índices Kappa para as classificações realizadas através do sistema IDRISI, que são apresentadas no Quadro 8, pois Ohata e Quintanilha (2005) apontam para a necessidade de utilização de especialista em

imagem e, principalmente de realidade de campo, pois as classificações não supervisionadas não apresentam, por si só, qualidade e, muito menos, confiabilidade.

Índice kappa	Integrador	Especialista	IDRISI Clust	IDRISI Iso	ENVI Iso	ENVI K
Recorte 1A	0,85	0,87	0,66	0,71	0,55	0,50
Recorte 1B	0,86	0,88	0,63	0,65	0,52	0,47
Recorte 1C	0,88	0,91	0,58	0,63	0,53	0,46

Quadro 8 - Índices Kappa das classificações realizadas pelo integrador, pela especialista e pelos sistemas IDRISI e ENVI.

Na comparação dos índices Kappa, as classificações piores foram as do sistema ENVI, mas sem significância estatística de forma a afirmar com segurança qual dos métodos – ISODATA ou K-MEANS – é o mais eficaz: tal impossibilidade é explicada devido aos métodos serem similares, como dito por ENVI (2009). Analisando os resultados dos índices Kappa para estes dois métodos, surpreendentemente há uma diferença estatística significativa nas classificações dos recortes 1B e 1C, que apresentaram diferenças superiores a 5%, mas inferiores a 15% (Quadro 8). Ohata e Quintanilha (2005) dizem que:

K-MEDIA apresenta maior confusão entre as classes, enquanto o ISODATA discrimina melhor cada alvo separando em uma classe distinta. Provavelmente, o recálculo dos intervalos de cada classe, através de suas médias móveis, somado a capacidade de dividir classes, juntar classes e eliminar classes menor que o limite estabelecido, favorece o ISODATA, dando-lhe uma maior flexibilidade e uma melhor discriminação dos diferentes alvos. No produto da classificação utilizando o K-MEDIA, existem mais classes “misturadas”, o qual sugere a necessidade de outros métodos de processamento para separar melhor as classes. O ISODATA resolve melhor estes problemas e gera uma classificação mais “limpa” na imagem bruta sem processamento anterior (OHATA; QUINTANILHA, 2005, p. 654).

Além disso, Gutiérrez (2003) indica que o método ISODATA apresenta problemas na representação de coberturas vegetais, o mesmo encontrado na classe Florestal dos recortes 1B e 1C, mas no recorte 1A houve representação acima de 50% por este método.

Dentre as classificações do sistema IDRISI, a função ISOCLUST apresentou resultados um pouco melhores que a CLUSTER, mas estes métodos também são baseados em inferências estatísticas e no pixel em si, sem levar em consideração seus vizinhos, o que explica resultados piores em suas classificações em relação ao índice Kappa frente ao integrador;

Observou-se que os índices Kappa das classificações dos sistemas computacionais IDRISI e ENVI se situaram abaixo dos índices alcançados pelas classificações do integrador, em concordância com a avaliação visual realizada no item 3.1. Tal fato se deve a utilização

por parte destes programas de métodos baseados somente em probabilidade e não em conhecimento, como o integrador.

3.3 Discussão dos resultados

ÁREAS	Quant. ajustes/ reclassif.	Índices iniciais de acerto						Índices finais de acerto						Índice médio final
		Água Part.	Água n Part.	Florestal	Sedimento	Área Const.	Manguezal	Água Part.	Água n Part.	Florestal	Sedimento	Área Const.	Manguezal	
Recorte 1A	21	76%	81%	70%	88%	65%	50%	88%	91%	82%	92%	79%	78%	85%
Recorte 1B	13	73%	80%	72%	---	69%	55%	88%	90%	86%	---	80%	82%	87%
Recorte 1C	7	79%	86%	75%	---	70%	52%	89%	94%	89%	---	81%	83%	89%
Média	-----	76%	82%	72%	88%	68%	52%	88%	92%	86%	92%	80%	81%	87%

Quadro 9 - Mostra do comportamento das assertivas do integrador implementado frente às classificações da especialista para cada um dos recortes da cena analisada.

O Quadro 9 apresenta o resultado do comportamento do integrador quanto aos critérios de parada estabelecidos no item 2.6.2, frente as classificações da especialista em imagem. As classes Água Particulada e Água não Particulada foram aquelas que apresentaram os melhores resultados com a necessidade de menos ajustes que as demais classes, o que mostra a validade deste tipo de proposta para uma boa e rápida tomada de decisão em termos de corpos hídricos.

A seguir seguem as classes na ordem crescente de dificuldade de ajuste, que implicou, conseqüentemente, em acertos menores na classificação: Água Particulada, Água não Particulada, Florestal, Área Construída e Manguezal. A classe Sedimento, apesar de só possuir representação significativa em um recorte (1A), apresentou um ótimo ajuste e classificação, se comparado à classe água.

Ressalta-se que a integração proposta realiza somente a classificação dos padrões em acordo com as classes de interesse e com a análise espectral proposta, significando que os padrões fora dos parâmetros da análise serão alocados como não interessantes ou desconhecidos (Classe Fora de Interesse ou Outros), não sendo “forçados” a pertencer a uma das classes de interesse.

Cabe aqui ressaltar que as classificações realizadas pela especialista foram comparadas com as resultantes do integrador por serem os tamanhos dos recortes selecionados muito grandes para a realização de trabalho de campo (necessário para comprovação da verdade de

campo ou terrestre), e por esta especialista já ter realizado dezenas de trabalhos nestas mesmas áreas, possuindo, conseqüentemente, comprovadas experiência e competência acumuladas nos seus mais de 40 anos de trabalho. Isto significa que somente tal comparação já é plenamente válida para teste do integrador, que, mesmo assim, foi também testado frente ao índice Kappa, obtendo índice representativo de ótima qualidade de classificação.

O tamanho dos recortes foi assim selecionado de forma a verificar a rapidez de resposta do integrador frente a uma área grande (maior que 600 km² e menor que 1.150 km²), significando que o seu uso para uma área menor é plenamente possível, o que não ocorreria caso os recortes escolhidos fossem muito pequenos. Assim posto, a integração proposta pode ser utilizada no auxílio de gestão de municípios com área inferior a 1.000 km².

Verificou-se a validade da integração proposta em termos de tendência a se tornar um classificador não supervisionado à medida da entrada de novas imagens, pois implica em maior aprendizado, visto que o primeiro recorte apresentou mais ajustes que os subsequentes: o integrador sofreu um decaimento na quantidade de ajustes devido ao aprendizado (Quadro 9). Além disso, o integrador obteve um índice Kappa médio de 0,86 (Quadro 8), indicativo de uma excelente qualidade de classificação, com qualidade bem próxima a da especialista de imagem (índice Kappa médio de 0,89).

Em termos de tempo de processamento, o IDRISI e o ENVI apresentaram um tempo médio de quatro minutos para a realização de cada uma das classificações. O integrador implementado, dispôs, em média, 2 minutos para o MLD, 8 minutos para o MRNC e 2 minutos para o MTD, com uma média total de 12 minutos para cada um dos recortes. As classificações realizadas pela especialista em imagem demandaram, em média, 30 horas para a realização de cada recorte da área-teste. Logo, em termos de processamento, apesar do integrador demandar o triplo do tempo que os programas ENVI e IDRISI, ele apresenta uma classificação superior a estes programas e em menos tempo que a especialista (150 vezes mais rápido), com uma classificação excelente, como indicado por Landis e Koch (1977) e Foody (1992, 2002) para um índice Kappa acima de 0,81.

A diferença de até 10% verificada nos valores obtidos da comparação das classificações do integrador com as da especialista frente ao índice Kappa (até 97% de concordância média dos resultados do integrador frente aqueles da especialista, resultado obtido com o cotejamento das duas colunas – Integrador e Especialista – do Quadro 8) com os valores obtidos da comparação direta dos resultados das classificações do integrador com as da especialista (até 87% de acertos de índice médio final do Quadro 9) deve-se ao fato que as classificações da especialista foram realizadas com base somente nas mesmas imagens utilizadas pelo integrador e no seu conhecimento adquirido, enquanto que no índice Kappa

foram utilizadas cartas, classificações e programas de visualização de terreno *online* para a extração de pontos dos recortes da área-teste, de forma a simular uma ida ao campo. Portanto, constata-se que mesmo a especialista, quando não auxiliada por outros meios que não somente a imagem de um terreno (utilização da interpretação visual) e a sua experiência, ainda sim pode cometer erros da ordem de até 32% ou 1σ , considerando-se uma distribuição normal para os erros, que são compatíveis com a média de discordância entre os especialistas de imagem com conhecimento de uma mesma região ou dos mesmos objetos geográficos em estudo.

Ressalta-se que a utilização do índice Kappa quando não associada a dados adquiridos em verdade de campo ou a dados adquiridos através de cartas e classificações confiáveis e idôneas irá expressar uma falsa qualidade (para pior ou para melhor) da classificação analisada.

4 CONCLUSÕES

A proposição de uma integração de técnicas de Análise Espectral e de Inteligência Computacional, baseada em Conhecimento de especialista, a partir do uso de imagens do LANDSAT-5, para as bandas 1 a 5 e 7, pôde ser validada através da classificação de cobertura e ocupação da terra envolvendo cinco classes de interesse (Água Particulada, Água não Particulada, Florestal, Área Construída e Manguezal) nos recortes da área-teste, situadas no Estado do Rio de Janeiro, 1A – Guaratiba, 1B- Mangaratiba e 1C – Magé.

A eficácia da integração proposta foi comprovada com a implementação desta em ambiente MATLAB, com a feitura dos módulos de Rede Neural Computacional (MRNC), de Lógica Difusa (MLD) e do Tomador de Decisão (MTD). Os MRNC e MLD utilizaram, respectivamente, os algoritmos SOFM e Mamdani do próprio MATLAB, sendo que o MTD foi implementado com regras estipuladas com a ajuda dos conhecimentos da especialista em imagem. Esta também supervisionou a escolha dos pixels que formaram o Banco de Assinaturas Espectrais (BAE), implementado no programa Excel, o qual foi modelado para a realização de cálculos estatísticos com base no conhecimento da especialista, fornecendo as regras e conjuntos de treinamento para os MLD e MRNC, respectivamente.

A eficácia das assertivas de cada uma das classes do integrador foi verificada com a comparação destas com as classificações da especialista, donde se destaca:

- As classes Água Particulada e Água não Particulada foram aquelas que obtiveram os melhores resultados na classificação final de todos os três recortes (alcançou média de 93% para Água não Particulada e média de 88% para Água Particulada), além de terem sido aquelas que necessitaram de menores ajustes antes da obtenção da classificação final, o que valida este integrador para uso na tomada de decisão de corpos hídricos; e
- As classes Manguezal e Área Construída obtiveram índices médios praticamente idênticos (81% e 80%), significando uma boa eficácia do integrador, visto estas classes serem as que apresentam maior dificuldade na classificação de padrões em imagens.

As classificações do integrador obtiveram resultado inferior ao da especialista, mas com índices abaixo de 3% em relação ao índice Kappa médio – 0,86 para o integrador e 0,89 para a especialista – e com um acerto, em média para todas as classes e para os três recortes, de 87% (individualmente para cada classe, alcançou acertos que variaram entre 80% a 94%)

em relação às classificações da especialista, significando que, em ambos os casos, a integração proposta logrou “adquirir” o conhecimento da especialista em imagem, pois se obteve um desvio-padrão inferior a 1σ ; além disso, a qualidade ótima das classificações do integrador foi comprovada pelo valor de 86% do índice Kappa. Tais resultados demonstram a assertiva da integração proposta em utilizar as assinaturas espectrais em conjunto com técnicas de inteligência computacional, baseadas em conhecimento de especialista em imagens.

Comprovou-se que as classificações não supervisionadas dos sistemas IDRISI e ENVI obtiveram qualidade de classificação inferior às apresentadas pela especialista, o que já era esperado frente aos trabalhos analisados e mencionados anteriormente, que obtiveram resultados semelhantes, pois estes sistemas realizam classificações sem a aplicação de conhecimento, utilizando somente técnicas clássicas estatísticas que não representam em sua totalidade a complexidade dos objetos geográficos presentes em uma imagem advinda de Sensoriamento Remoto.

Verificou-se a validade da integração proposta em termos de tendência a se tornar um classificador não supervisionado à medida da entrada de novas imagens, pois o integrador sofreu um decaimento significativo na quantidade de ajustes devido ao aprendizado. Em termos de processamento o integrador apresentou um tempo 150 vezes mais rápido e com índice de acerto médio de até 87% em comparação as classificações da especialista em imagem.

Destaca-se que no estágio atual do integrador, com a utilização de cenas do LANDSAT (limitação da resolução de objetos geográficos em 30m), ele é indicado para o mapeamento de áreas críticas, a avaliação de impactos ambientais e a exploração dos recursos minerais, bem como para o mapeamento cartográfico em pequenas escalas. Esta integração proposta viabiliza uma solução tanto para o planejamento regional como para o de área agrícola, significando uma ferramenta indispensável ao gestor público, principalmente de municípios com área inferior a 1.000 km².

Com base nos resultados positivos obtidos com o integrador proposto, implementado em ambiente MATLAB, o qual propicia uma resposta bem mais rápida de resultados do que a implementação de uma ferramenta computacional plenamente desenvolvida, a qual acarretaria enormes esforços em aprendizado e utilização de linguagens de programação, destacam-se as seguintes recomendações e consequentes trabalhos futuros:

- ✓ Teste do atual estágio do integrador para outras cenas do LANDSAT-5 de forma a avaliar a estabilidade do conhecimento adquirido;

- ✓ Implementação de novos algoritmos baseados em SOFM e em Mamdani que já tenham incorporados o conhecimento de especialista em imagem;
- ✓ Implementação do integrador como uma ferramenta computacional ou como um módulo de um Sistema de Informação Geográfica (SIG);
- ✓ A adaptação dos parâmetros da pré-classificação realizada, antes da entrada do integrador, para um novo tipo de segmentação com base nas técnicas de crescimento por regiões, limiarização ou agrupamento (*clustering*) com a utilização do conhecimento de especialista em imagem;
- ✓ A aplicação de um modelo de mistura, onde o valor do pixel é considerado como uma combinação da resposta de cada objeto contido no elemento da cena, com base no conhecimento de especialista em imagem;
- ✓ Ampliação do banco de assinaturas espectrais (BAE) como um banco de dados efetivo (Banco de Dados de Assinaturas Espectrais – BDAE) de forma a incluir os dados ambientais da cena (como umidade e temperatura), o que agregará um incremento de valor na classificação, com a possibilidade de utilização de cenas temporais;
- ✓ Implementação de uso de um número maior de sensores orbitais, bem como os aerotransportados, mas que sejam, no mínimo, multiespectrais e, preferencialmente, hiperespectrais, seguindo os mesmos moldes da integração proposta irá tornar a classificação ainda mais eficaz;
- ✓ Ampliação da resolução espectral dos sensores utilizados na integração, com o concurso de um maior número de sensores multiespectrais e, principalmente, hiperespectrais, tornará a integração incrivelmente mais eficaz, na medida em que o poder resolutivo das classes ou alvos será muito ampliado;
- ✓ A inclusão de imagens que necessitem de técnicas de pré-processamento para correções de distorções radiométricas, geométricas (sejam do sensor ou para registro da imagem) ou atmosféricas devem ser bem avaliadas, pois estas causam distorções na radiometria o que implica na alteração da correlação espectral dos pixels estabelecida por esta proposição;
- ✓ A incorporação de outras técnicas, como as de classificação por textura (LOCK; KIRCHNER, 1997; SETTE, 2009), na integração certamente contribuirá para o aumento do poder de resolução da classificação final;
- ✓ A consideração de outras técnicas de IC (como Algoritmos Genéticos e *Simulated Annealing*) na integração que sejam calcadas, fundamentalmente,

em modelos de correlação entre quantizações dos pixels nas diversas bandas espectrais irá agregar, sem sombra de dúvida, valor a integração proposta;

- ✓ Incorporação de inferência bayesiana em conjuntos com as técnicas de Inteligência Computacional para proporcionar uma melhor modelagem da incerteza presente nas classes e, conseqüentemente, nas assinaturas espectrais;
- ✓ Incorporação de proposta de El-Saba, Alam e Sakla (2010) no integrador com a utilização de fusão de dados e da informação polarizada para a melhora da classificação, de forma a diminuir os falsos positivos da classificação dos alvos de interesse; e
- ✓ Utilização da integração proposta como o cerne de um futuro sistema especialista.

REFERÊNCIAS

AGUIAR, H; JÚNIOR, O. *Lógica Difusa: Aspectos práticos e aplicações*. 1. ed. Rio de Janeiro: Editora Interciência LTDA, 1999. 192 p.

ALVES, C. A. *Estimativa da área impermeável dentro da bacia hidrográfica do Arroio Dilúvio (Porto Alegre/RS) através de técnicas de sensoriamento remoto e geoprocessamento*. [base de dados na Internet] 2005. 137 p. Dissertação (Mestrado em Sensoriamento Remoto) – Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia – CEP SRM, Universidade Federal do Rio Grande do Sul – UFRGS, Porto Alegre, 2004. Disponível em: <<http://www.lume.ufrgs.br/bitstream/handle/10183/5093/000509929.pdf?sequence=1>>. Acesso em: 12 mar. 2010.

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*. Secretaria de Planejamento da Presidência da República. Fundação Instituto Brasileiro de Geografia e Estatística (IBGE), Diretoria Técnica, Superintendência de Recursos Naturais e Meio Ambiente (SUPREN). Rio de Janeiro: IBGE, 1979. 78 p.

ANDERSON, Paul Simon, (Ed.) *Fundamentos para Fotointerpretação*. Rio de Janeiro: Sociedade Brasileira de Cartografia, 1982. 139 p.

ARIAS, S.; GÓMEZ, H.; PRIETO, F.; BOTÓN, M.; RAMOS, R. Satellite Image Classification by Self-Organized Maps on GRID Computing Infrastructures. [base de dados na Internet]. In: R. Mayo et al, editores. CIEMAT 2009. *Proceedings of the Second EELA-2 Conference*; 2009. p. 1-11. Disponível em: <http://www.ceta-ciemat.es/attachments/320_Satellite_Image_Classification_by_%20SOM_on_GRID.pdf>. Acesso em: 17 maio 2010.

AVERY, T. E.; BERLIN, G. L. *Fundamentals of Remote Sensing and Airphoto Interpretation*. 5. ed. New Jersey: Prentice Hall, 1992. 472 p.

AZEVEDO, E.; CONCI, A. *Computação Gráfica: teoria e prática*. 3ª reimpressão. Rio de Janeiro: Elsevier, 2003. 353 p.

BECERRA, J. A. B., BITENCOURT, M. D. A classificação contínua (fuzzy) no mapeamento temático de áreas do cerrado. [base de dados na Internet]. *Anais do Simpósio Brasileiro de Sensoriamento Remoto (SBSR2003)*, 11.; 2003; Belo Horizonte, Minas Gerais, Brasil. São José dos Campos, SP: INPE, 2003. p. 2663-2670.

BITTENCOURT, G. *Representação de conhecimento: da metafísica aos programas*. [base de dados na Internet]. In: SBC. (Org.). *Cursos JAI'98*. Belo Horizonte: UFMG, 1998. p. 283-333. Disponível em: <<http://www.das.ufsc.br/~gb/pg-ia/rdec.pdf>>. Acesso em: 9 mar. 2007.

BLASCHKE, T.; KUX, H. (editores) *Sensoriamento remoto e SIG avançados: novos sistemas e sensores inovadores*, 2. ed. São Paulo: Oficina de Textos, 2007. 304 p.

BOLFE, E. L.; FONSECA, E. L. da; PEREIRA, R. S.; MADRUGA, P. R. de A. Verificação da exatidão em classificação digital de povoamentos florestais em imagem orbital mediante três índices. [base de dados na Internet]. *Anais do Simpósio Brasileiro de Sensoriamento Remoto* (SBSR2003), 11.; 2003; Belo Horizonte, Minas Gerais, Brasil. São José dos Campos: INPE, 2003. p. 2671-2677. Disponível em:

<http://mar.te.dpi.inpe.br/col/ltid.inpe.br/sbsr/2002/11.17.01.22/doc/19_290.pdf>. Acesso em: 13 mar. 2012.

CAIMI, D. *O problema do pixel mistura: um estudo comparativo*. [base de dados na Internet] 1993. 117 p. Dissertação (Mestrado em Sensoriamento Remoto) – Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia – CEPARM, Universidade Federal do Rio Grande do Sul – UFRGS, Porto Alegre, 1993. Disponível em:

<<http://www.lume.ufrgs.br/bitstream/handle/10183/1373/000106990.pdf?sequence=1>>. Acesso em: 12 mar. 2010.

CAMPANA, N. A. *Estimativas de parâmetros físicos de bacias utilizando técnicas de sensoriamento remoto e o sistema de informações geográficas*. [base de dados na Internet] 1992. 88 p. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas – IPH, Universidade Federal do Rio Grande do Sul – UFRGS, Porto Alegre, 1992.

CALDAS, N. S. da S.; GUERRA, C. E. Sistema de Classificação Fuzzy não supervisionada aplicada a detecção de savanas na região de Santarém-PA. [base de dados na Internet]. *Anais do Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação* (III SIMGEO), 3.; 27-30 jul. 2010; Recife, Pernambuco, Brasil. 2010. p. 000-000. Disponível em: <http://www.ufpe.br/cgtg/SIMGEOIII/IIISIMGEO_CD/artigos/FotoeSR/SR_e_PDI/A_83.pdf>. Acesso em: 21 mar. 2012.

CASANOVA, Marco; CÂMARA, Gilberto; DAVIS, Clodoveu; VINHAS, Lúbia; QUEIROZ, Gilberto R. de. *Banco de Dados Geográficos*. [livro na Internet] Disponível em: <<http://www.dpi.inpe.br/gilberto/livro/bdados/capitulos.html>>. Acesso em: 02 abr. 2007.

CBERS - *Satélite Sino-Brasileiro de Recursos Terrestres*. [página na Internet] Instituto Nacional de Pesquisas Espaciais – INPE. 2006. Disponível em: <<http://www.cbears.inpe.br/>>. Acesso em: 03 maio 2007.

CIDE - *Centro de Informações e Dados do Rio de Janeiro*. [página na Internet] 2009. Disponível em: <<http://www.cide.rj.gov.br/download/territorio/territorios.asp>>. Acesso em: 30 mar. 2009.

CONSOLE, E.; MOUCHOT, M. C. Fuzzy Classification Techniques in the Urban Area Recognition. *Proceedings of IEEE Geoscience and Remote Sensing Symposium* (IGARSS'96), Remote Sensing for a Sustainable Future; 1996 May 27-31. v. 2. USA: Lincoln, NE; 1996. p. 1373-1375.

CONWAY, Eric D.; The Maryland Space Grant Consortium. *An Introduction to Satellite Image Interpretation*. USA: The John Hopkins University Press, 1997. 242 p.

CRÓSTA, A. P. *Processamento Digital de Imagens de Sensoriamento Remoto*. ed. rev. 4. reimpressão, 2002. Campinas, SP: Instituto de Geociências – IG/UNICAMP, 1992. 170 p.

CPRM – Companhia de Pesquisa de Recursos Minerais. *Unidades Geomorfológicas do Estado do Rio de Janeiro*. [página na Internet] Projeto Rio de Janeiro. Geomorfologia, Cap. 3. 2006. Disponível em: <ftp://ftp.cprm.gov.br/pub/pdf/rj/geomorfologico/geomorfounidades.pdf>. Acesso em: 03 jul. 2009.

EASTMAN, J.R. *Idrisi 15: The Andes Edition*. Worcester, MA: Clark University, 2006.

EL-SABA, Aed; ALAM, Mohammad S.; SAKLA, Wesam A. Pattern recognition via multispectral, hyperspectral and polarization-based imaging. Invited Paper. Proceedings of International Society for Optics and Photonics (SPIE): *Automatic Target Recognition, 20.; Acquisition, Tracking, Pointing, and Laser Systems Technologies, 24.; and Optical Pattern Recognition, 21.; April 05, 2010*. v. 7696. 76961M; USA: Orlando, Florida, 2010.

EMBRAPA – Monitoramento por Satélite. *LANDSAT – Land Remote Sensing Satellite*. [página na Internet] Sistemas Orbitais de Monitoramento e Gestão Territorial. Empresa Brasileira de pesquisa Agropecuária. Ministério da Agricultura, Pecuária e Abastecimento. 2008. Disponível em: <http://www.sat.cnpm.embrapa.br/conteudo/LANDSAT.htm#tm>. Acesso em: 03 jul. 2009.

ENGELBRECHT, A. P. *Computational Intelligence: An Introduction*. Second edition. Pretória: Wiley, 2007. 628 p.

ENVI - *Environment for Visualizing Images*. [página na Internet] 2011. Guia do ENVI. Disponível em: <http://www.sulsoft.com.br/index.php/arearestrita/>. Acesso em: 04 jan. 2012.

FERREIRA, Aurélio Buarque de Holanda. *Novo Dicionário Aurélio da Língua Portuguesa*. [programa de computador] Dicionário eletrônico. 3. ed. 1. impressão da Editora Positivo, revista e atualizada do Aurélio Século XXI. Editora Positivo Informática LTDA, 2004.

FIQUEIREDO, G. C., VIEIRA, C. A. O. Estudo do comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto. [base de dados na Internet] *Anais do Simpósio Brasileiro de Sensoriamento Remoto (SBSR2007)*, 13.; 2007; Florianópolis. São José dos Campos: INPE; 2007. p. 5755–5762. Disponível em: <http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.13.17.35/doc/5755-5762.pdf>. Acesso em: 25 mar. 2011.

FLORENZANO, Teresa Galloti. *Imagens de Satélite para Estudos Ambientais*. São Paulo: Oficina de Textos, 2002. 97 p.

FOODY, G. M. Fully Fuzzy Supervised Classification of Land Cover from Remotely Sensed Imagery with an Computational Neural Network. *Neural Computing & Applications*. v. 5. n. 4. 1997. p. 238-247.

FOODY, G. M. On the compensation for chance agreement in image classification accuracy assessment. *Photogrametric Engineering and Remote Sensing*, v. 58. n. 10. 1992. p. 1459-1460.

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

FREITAS, R. M. ; ADAMI, M. ; RUDORFF, Bernardo Friedrich Theodor ; SHIMABUKURO, Yosio Edemir ; ROSA, R. R. ; SILVA, J.D.S. ; ARCOVERDE, G.F.B. . Análise exploratória de dados multitemporais de sensoriamento remoto usando mapas auto-organizáveis: estudo em áreas de expansão da cana-de-açúcar. [base de dados na Internet]. *Anais do Simpósio Brasileiro de Sensoriamento Remoto*, 14.; 2009; Natal. v. 1. São José dos Campos: INPE, 2009. p. 7797-7804. Disponível em: <<http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr%4080/2008/11.14.18.32/doc/7797-7804.pdf>>. Acesso em: 10 mar. 2010.

FU, LiMin. *Neural Networks in Computer Intelligence*. Computer Science Series. Singapore: McGraw-Hill International Editions, 1994. 460 p.

GARCIA, G.J. *Sensoriamento Remoto: Princípios e Interpretação de Imagens*. Nobel, São Paulo, 1982. 357 p.

GIMP – *The GNU Image Manipulation Program*. [página na Internet] *The GIMP Team*. 2009. Disponível em: <<http://www.gimp.org/>>. Acesso em: 02 ago. 2009.

GONÇALVES, M. L.; NETTO, M. L. de A.; ZULLO JR., J.; COSTA, J. A. F. Classificação não-supervisionada de imagens de sensores remotos utilizando redes neurais auto-organizáveis e métodos de agrupamentos hierárquicos. [base de dados na Internet]. *Revista Brasileira de Cartografia*, n. 60/1. Abril. Rio de Janeiro, 2008. Disponível em: <<http://www.lsie.unb.br/rbc/index.php/rbc/article/view/324/314>>. Acesso em: 17 mar. 2010.

GONÇALVES, M. L.; NETTO, M. L. A.; ZULLO JR., J. Um Sistema Neural Modular para Classificação de Imagens utilizando Mapas de Kohonen. [base de dados na Internet]. *Anais do Simpósio Brasileiro de Sensoriamento Remoto*, 8.; 14-19 abril, 1996; Salvador, Brasil. São José dos Campos: INPE; 1996. p. 845-849. Disponível em: <<http://marte.dpi.inpe.br/col/sid.inpe.br/deise/1999/02.01.15.50/doc/T37.pdf>>. Acesso em: 17 mar. 2010.

GONÇALVEZ, M. L. *Uma arquitetura neural modular para classificação de imagens multiespectrais de sensoriamento remoto*. 1997. 112 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 1997.

GONG, P.; HOWARTH, P. J. A graphical approach for evaluation of land-cover classification procedures. *International Journal of Remote Sensing*, v. 11(5). 1990. p. 899-905. Disponível em: <<http://nature.berkeley.edu/~penggong/PDFpapers/GongIJRS90Prob.pdf>>. Acesso em: 15 mar. 2012.

GONZALEZ, R. C.; WOODS, R. E. *Processamento de Imagens Digitais*. São Paulo, Brasil: Editora Edgard Blücher LTDA, 2000. 528 p.

GOOGLE EARTH. [programa na Internet] Página do Google Earth. Disponível para *download*. Gratuito. 2012. Disponível em: <<http://www.google.com/earth/index.html>>. Acesso em: 04 out. 2012.

GSI - Grupo de Sistemas Inteligentes. *Uma Introdução às Redes Neurais*. [página na Internet] Departamento de Informática – DIN. Universidade Estadual de Maringá – UEN. 1999. Disponível em: <<http://www.din.uem.br/ia/download/neurais.zip>> Acesso em: 13 dez. 2007.

GUDWIN, R. R.; GOMIDE, A. C. *Sistemas Inteligentes Semióticos Segundo a Semiótica Behaviorista de Charles Morris*. [página na Internet] DCA/FEE/UNICAMP. 2006. Disponível em: <<http://www.dca.fee.unicamp.br/~gudwin/ftp/publications/morris.pdf>>. Acesso em: 12 mar. 2009.

GUTIÉRREZ, M. A. *Clasificación no supervisionada de coberturas vegetales sobre imágenes digitales de sensores remotos: “LANDSAT- ETM”*. [página na Internet] 2003. 103 p. Dissertação (Magíster em Ingeniería de Sistemas) – Facultad Nacional de Minas, Universidad Nacional de Colombia – Medellín, 2003. Disponível em: <http://www2.unalmed.edu.co/minas/index2.php?option=com_docman&task=doc_view&gid=994&Itemid=57>. Acessado em: 17 mar. 2010.

HAYKIN, Simon. *Redes Neurais – Princípios e Prática*. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

HOWSTUFFWORKS. *Como Tudo Funciona. Como funciona a radiação dos telefones celulares*. [página na Internet] Página sediada no Brasil pela UOL. HSW International, Inc. 2001. Disponível em: <<http://informatica.hsw.uol.com.br/radiacao-dos-telefones-celulares1.htm>>. Acesso em: 15 nov. 2012.

IBGE – Instituto Brasileiro de Geografia e Estatística. *Manual Técnico de Uso da Terra*. [base de dados na Internet] 2. ed. Manuais Técnicos em Geociências, número 7. Diretoria de Geociências. Coordenação de Recursos Naturais e Estudos Ambientais. Ministério do Planejamento, Orçamento e Gestão. Rio de Janeiro, 2006. Disponível em: <ftp://geofp.ibge.gov.br/documentos/recursos_naturais/manuais_tecnicos/manual_uso_da_terra.pdf>. Acesso em: 12 dez. 2011.

IDRISI Selva – *GIS and Image Processing Software*. [página na Internet] Página da SulSoft, distribuidora exclusiva dos produtos da Clark Labs no Brasil. 2012. Disponível em: <<http://www.idrisi.com.br/index.php>>. Acesso em: 13 jun. 2012.

INEA – Instituto Estadual do Ambiente. [página na Internet] Página do Governo do Estado do Rio de Janeiro. 2012. Disponível em: <<http://www.inea.rj.gov.br/index/index.asp>>. Acesso em: dez. 2012.

INPE - Instituto Nacional de Pesquisas Espaciais. *Programa MARLIN*. [página na Internet] AMS Kepler. 2009. Disponível em: <<http://www.dgi.inpe.br/Suporte/files/marlin-3-1-2.msi>>. Acesso em: 15 jul. 2009.

_____. *Catálogo de Imagens. Imagens dos satélites LANDSAT-1, LANDSAT-2, LANDSAT-3, LANDSAT-5, LANDSAT-7, CBERS-2 e CBERS-2B (Satélite Sino-Brasileiro de Recursos Terrestres)*. [base de dados na Internet]. 2011. Disponível em: <<http://www.dgi.inpe.br/CDSR/>>. Acesso em: 12 jun. 2009.

_____. *Os satélites LANDSAT 5 e 7*. [página na Internet] Instituto Nacional de Pesquisas Espaciais – INPE. 2012. Disponível em: <http://www.dgi.inpe.br/Suporte/files/Cameras-LANDSAT57_PT.php>. Acesso em: 13 mar. 2012.

ITRES. *Baseline Coastal Survey & Classification Product Derived From CASI Data - ITRES Research*. [página na Internet] Canada. Calgary, Alberta: 2007. Disponível em: <http://www.itres.com/Baseline_Coastal_Survey>. Acesso em: 02 ago. 2007.

JENSEN, J. R. *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*. Tradução da 2. ed. por pesquisadores do INPE: José Carlos N. Epiphânio (coordenador); Antonio R. Formaggio; Athos R. Santos; Bernardo F. T. Rudorff; Cláudia M. Almeida; Lênio S. Galvão. São José dos Campos: Parêntese, 2009. 672 p.

KOHONEN, T. *Self-Organization and Associative Memory*. Springer, 1984. 255 p.

KOHONEN, T. *Self-Organizing Maps*. 3. ed. Springer series in information; 30. Berlin; Heidelberg; New York; Barcelona; Hong Kong; London; Milan; Paris; Singapore; Tokyo: Springer, 1997. 426 p.

KOSKO, Bart. *Fuzzy Thinking: The new science of fuzzy logic*. Hammersmith: Flamingo, 1994. 336 p.

LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. *Biometrics*, v. 33. n.1. p. 159-174. 1977.

LANDSAT – *Land Remote Sensing Satellite*. [página na Internet] Sistemas Orbitais de Monitoramento e Gestão Territorial. EMBRAPA Monitoramento por Satélite. Ministério da Agricultura, Pecuária e Abastecimento. 2011. Disponível em: <<http://www.sat.cnpm.embrapa.br/conteudo/landsat.htm>>. Acesso em: 15 nov. 2012.

LILLESAND, Thomas M.; KIEFER, Ralph W. *Remote sensing and Image Interpretation*. 3. ed. USA: John Wiley & Sons, 1994. 750 p.

LIN, A. L.; IMAI, F. Efficient spectral imaging based on imaging systems with scene adaptation using tunable color pixels. *Proceedings of the Color Imaging Conference*, 19. Society for Imaging Science and Technology, 2011. p. 332–338.

LOCK, Ruth E. N.; KIRCHNER, Flávio F. Classificação de Imagens Multiespectrais LANDSAT TM e Feições de Textura: Mapeamento da Cobertura da Terra. [revista na Internet]. *Revista Floresta*. Curitiba, v. 27. n. 1/2. p. 41-58. 1997. Disponível em: <<http://ojs.c3sl.ufpr.br/ojs2/index.php/floresta/article/viewFile/2297/1917>>. Acesso em: 01 out. 2012.

LUIZ, A.J.B.; GÜRTLER, S.; GLERIANI, J. M.; EPIPHANIO, J.C.N.; CAMPOS, R. C. Reflectância a partir do número digital de imagens ETM+. [base de dados na Internet] *Anais do Simpósio Brasileiro de Sensoriamento Remoto (SBSR2003)*, 11., 2003; Belo Horizonte, MG. Biblioteca digital URLib. São José dos Campos: INPE; 2003. p. 2071-2078. Disponível em: <http://lagavulin.ltid.inpe.br:1905/col/ltid.inpe.br/sbsr/2003/03.27.11.57/doc/15_015.PDF>. Acesso em: 07 set. 2009.

MA, Z.; REDMOND; R. L. Tau coefficients for accuracy assessment of classification of remote sensing data. *Photogram. Eng. Remote Sensing*. v. 61. p. 435–439. 1995.

MAMDANI, E.H.; ASSILIAN, S. An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*. v. 7. n. 1. p. 1-13. 1975.

MATLAB – *The Language of Technical Computing*. 2010. Disponível em: <<http://www.mathworks.com/products/matlab/>>. Acesso em: 12 mar. 2011.

MEIRELLES, M. S. P.; CÂMARA, G.; ALMEIDA, C. M, *Geomática - Modelos e Aplicações Ambientais*. Brasília, DF: EMBRAPA Informação Tecnológica, 2007. 593 p.

MENESES, P. R.; NETTO, J. da S. M. *Sensoriamento Remoto: Reflectância dos Alvos Naturais*. EMBRAPA. Brasília, DF: UnB; Planaltina: EMBRAPA Cerrados, 2001. 262 p.

MOREIRA, M.A. *Fundamentos de Sensoriamento Remoto e Metodologias de Aplicação*; 3. ed. atualizada e ampliada. Viçosa, MG: Ed. UFV, 2005. 320 p.

MERÉNYI, E.; VILLMANN, T. Self-Organizing Neural Net Approaches For Hyperspectral Images. *Proceedings of International Conference on Intelligent Computing and Information Systems*. Jun 24 - 26, 2002; Cairo, Egypt. p. 1-9.

MORETTI, A. I. P.; FERREIRA, M. C.; MATTOS, E. C. A.; TRENTIN, G. Avaliação de métodos de classificação supervisionada para o mapeamento da cobertura vegetal nativa da Área de Proteção Ambiental Fernão Dias a partir de imagem Landsat. [base de dados na Internet] *Anais do Simpósio Brasileiro de Sensoriamento Remoto (SBSR2011)*, 15.; 2011; Curitiba. São José dos Campos: INPE; 2011. p. 7279-7285. Disponível em: <<http://urlib.net/3ERPFQTRW/3A3NMB2>>. Acesso em: 30 ago. 2012.

MORIN, Edgar, CIURANA, Emilio Roger, MOTTA, Raúl Domingo. *Educar na era planetária: o pensamento complexo como método de aprendizagem no erro e na incerteza humana*. 2. ed. São Paulo. Cortez, Brasília, DF: UNESCO, 2007. 111 p.

MUEHE, Dieter; VALENTINI, Enise. *O Litoral do Estado do Rio de Janeiro: uma caracterização físico-ambiental*. [livro na Internet] Programa de Pós-Graduação em Geografia da UFRJ. 2009. Disponível em:

<http://www.ppgg.igeo.ufrj.br/livros/dieter/litoral_rio_68.pdf>. Acesso em: 30 mar. 2009.

NANNI, H. C.; NANNI, S. M.; SEGNINI, R. C. A importância dos manguezais para o equilíbrio ambiental. [base de dados na Internet] *Anais do Simpósio Internacional de Ciências Integradas (SICI2005)*, 2.; 2005; Ribeirão Preto: Universidade de Ribeirão Preto – UNAERP – Campus Guarujá; 2005. 12 p. Disponível em: <http://www.unaerp.br/sici/pt/edicoes-antteriores/doc_download/452-a-importancia-dos-manguezais-para-o-equilibrio-ambiental->. Acesso em: 30 ago. 2012.

NASA – National Aeronautics and Space Administration. [página na Internet] *The Landsat Program*. 2012. Disponível em: <<http://landsat.gsfc.nasa.gov/>>. Acesso em: dez. 2012.

NASCIMENTO JR, Cairo Lúcio; YONEYAMA, Takashi, *Inteligência Computacional em Controle e Automação*. 1. ed. São Paulo: Edgard Blucher, 2000. 228 p.

NISHIDA, W. *Uma Rede Neural Artificial para Classificação de Imagens Multiespectrais de Sensoriamento Remoto*. [página na Internet] Dissertação de mestrado em Engenharia de Produção. Centro Tecnológico da Universidade Federal de Santa Catarina. Florianópolis, fevereiro de 1998. Disponível em: <<http://www.eps.ufsc.br/disserta98/waleska/index.htm>>. Acesso em: 15 out. 2008.

NOGUCHI, M. T. G. *Um sistema baseado em regras fuzzy para classificação supervisionada de imagens multiespectrais de alta resolução*. [base de dados na Internet] 2004. 150 p. Dissertação (Mestrado em Informática) – Setor de Ciências Exatas, Universidade Federal do Paraná, Curitiba, 2004. Disponível em:

<<http://dspace.c3sl.ufpr.br/dspace/bitstream/handle/1884/660/dissertacao.pdf?sequence=1>>.

Acesso em: 02 jul. 2007.

NOVO, E. M. L. de M. *Sensoriamento Remoto: princípios e aplicações*. 3. ed. São Paulo: Edgard Blucher, 2008. 388 p.

OHATA, A. T.; QUINTANILHA, J. A. O uso de algoritmos de *clustering* na mensuração da expansão urbana e detecção de alterações na Região Metropolitana de São Paulo (1991-2002). [base de dados na Internet]. *Anais do Simpósio Brasileiro de Sensoriamento Remoto (SBSR2005)*, 12.; 16-21 abril de 2005; Goiânia, Brasil. São José dos campos: INPE; 2005. p. 647-655. Disponível em:

<<http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.21.15.43/doc/647.pdf>>. Acesso em: 15 jul. 2009.

PESCHEL, J. M. *Creating Land Cover Input Datasets for the SWAT 2000 Model Using Landsat Imagery*. [página na Internet] Dissertação. Master of Science. Department of Civil Engineering. Texas A&M University. 2002. Disponível em:

<<https://ceprofs.tamu.edu/folivera/TxAgGIS/Spring2002/Peschel/peschel.htm>>. Acesso em: 15 out. 2008.

PRADO, F. de A.; GALO, M. de L. B. T. Classificação de Imagens Multiespectrais baseada em abordagem Fuzzy. *Revista Brasileira de Cartografia*. n. 61/3. p. 233-144. Outubro de 2009.

PONZONI, F. J.; SHIMABUKURO, Y. E. *Sensoriamento remoto no estudo da vegetação*. São José dos Campos, SP: A. Silva Vieira, 2009. 144 p.

RODRIGUES, L. M.; RESENDE, M. R.; TIMOSZCZUK, A. P. Sistema de imageamento hiperespectral de alta resolução embarcado em plataforma aérea de baixo custo. [base de dados na Internet]. *Anais do Simpósio Brasileiro de Sensoriamento Remoto (SBSR2007)*, 13.; 2007; Florianópolis. São José dos Campos: INPE, 2007. p. 7079-7085. Disponível em: <<http://urlib.net/dpi.inpe.br/sbsr@80/2006/11.14.22.45>>. Acesso em: 12 set. 2012.

SALMAN, M. AW.; SENO, N. E. West of Iraq Satellite Image Classification using Fuzzy Logic. *Journal of Kufa for Mathematics and Computer*. v. 1. n. 4. p. 36-48. Nov., 2011. Disponível em: <<http://www.iasj.net/iasj?func=fulltext&aId=36965>>. Acesso em: 15 jan. 2012.

SCHROETER, L.; GLÄBER, C. Analyses and monitoring of lignite mining lakes in Eastern Germany with spectral signatures of Landsat TM satellite data. *International Journal of Coal Geology*. n. 86. p. 27-39. Science Direct, 2011,

SCHOWENGERDT, R. A. *Remote Sensing: Models and Methods for Image Processing*. 2. ed. USA: Academic Press NY, 1997. 522 p.

SETTE, Priscila G. C. *Análise de Textura de Imagem de Alta Resolução para a Classificação dos Estágios Sucessionais de Mata Atlântica do Sul da Bahia*. [base de dados na Internet] 2009. 73 p. Dissertação (Mestrado em Análise e Modelagem de Sistemas Ambientais) – Instituto de Geociências, Universidade Federal de Minas Gerais, Belo Horizonte, 2009. Disponível em: <http://www.csr.ufmg.br/modelagem/dissertacoes/priscila_sette.pdf>. Acesso em: 20 ago. 2012.

SHAW, G.A. and BURKE, H.K. Spectral Imaging for Remote Sensing. *Lincoln Laboratory Journal*, v.14, n.1, 2003. Disponível em:<http://www.ll.mit.edu/publications/journal/pdf/vol14_no1/14_1remotesensing.pdf>. Acesso em: 01 maio 2012.

SHANI, A. *Landsat image classification using fuzzy sets rule base theory*. 2006. 67 p. Dissertação. [base de dados na Internet] Master's Theses. Paper 2978. SJSU ScholarWorks, San Jose State University, 2006. Disponível em: <http://scholarworks.sjsu.edu/cgi/viewcontent.cgi?article=3974&context=etd_theses>. Acesso em: 02 mar. 2009.

SILVA, M. A. S. da; MONTEIRO, A. M. V.; MEDEIROS, J. S. de. Geografia Computacional: Um experimento em Inferência Geográfica com Redes Neurais Artificiais. INPE. [base de dados na Internet] *Workshop dos Cursos de Computação Aplicada do INPE (WORCAP)*, 2.; 20 e 21 de Novembro de 2002; São José dos Campos, SP. INPE, 2002. Disponível em: <[http://mtc-m18.sid.inpe.br/col/lac.inpe.br/lucio/2002/11.11.09.58/doc/artigo_worcap\(versao_final\).pdf](http://mtc-m18.sid.inpe.br/col/lac.inpe.br/lucio/2002/11.11.09.58/doc/artigo_worcap(versao_final).pdf)>. Acesso em: 02 mar. 2009.

SILVA, N. C. da. *Classificação Semi-Automática de Imagens de Sensoriamento Remoto por meio de Síntese Genética de Redes Neurais Artificiais*. [base de dados na Internet] 2003. 120 p. Tese (Doutorado em Geologia) – Instituto de Geociências, Universidade de Brasília, Brasília, 2003.

SPRING – *Sistema de Processamento de Informações Georreferenciadas*. [programa de computador] Página do sistema. Divisão de Processamento de Imagens – DPI. Instituto Nacional de Pesquisas Espaciais – INPE. 2012. Disponível em: <<http://www.dpi.inpe.br/spring/portugues/index.html>>. Acesso em: 12 jul. 2012.

SUGUIO, Kenitiro. *Dicionário de Geologia Sedimentar e Áreas Afins*. Rio de Janeiro: Bertrand Brasil, 1998. 1217 p.

SUMATHI, S.; PANEERSELVAM, S. *Computational Intelligence Paradigms: Theory & applications using MATLAB*. Boca Raton: CRC Press, Taylor & Francis Group, 2010. 834 p.

TEIXEIRA, K. D. S. *Estudo da Viabilidade da Classificação Automática de Imagens baseada em Registros Digitais e em Inteligência Computacional*. [página na Internet]. Dissertação (Mestrado em Engenharia da Computação) – Departamento de Geomática, Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro (UERJ), Rio de Janeiro, 2004. Disponível em: <http://www.geomatica.eng.uerj.br/_media/teses:karlat.tar.gz?id=dissertacoes&cache=cache>. Acesso em: 21 ago. 2006.

_____. *Banco de dados de assinaturas de registros digitais obtidos por sensoriamento remoto: uma proposta de conteúdo*. Dissertação (Monografia de conclusão de graduação) – Departamento de Engenharia Cartográfica, Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro (UERJ), Rio de Janeiro, 2008.

_____. Spectral Analysis, Computational Intelligence and Knowledge Integration for Automatic Pattern Recognition from Multispectral Scenes. [base de dados na Internet] *Proceedings of International Conference on Systems, Signals and Image Processing (IWSSIP 2010)*, 17.; 2010, Rio de Janeiro, Brasil. 2010. p. 384-387. Disponível em: <http://www.ic.uff.br/iwssip2010/Proceedings/nav/papers/paper_120.pdf>. Acesso em 04 jan. 2011.

TOU, J. T., GONZALEZ, R. C. *Pattern recognition Principles*. Addison-Wesley Publishing Company. Reading, Massachusetts, 1974. 377 p.

USGS. *USGS Spectroscopy Lab – Tetracorder*. [página na Internet] United States Geological Survey – USGS. 2004. Disponível em: <http://speclab.cr.usgs.gov/tetracorder.html>>. Acesso em: 04 jul. 2007.

VIEIRA, Carlos A. O. *Técnicas de Classificação Não-Supervisionada em Imagens Digitais Multiespectrais*. 1993. Dissertação (Mestrado em Sistemas e Computação) – Instituto Militar de Engenharia (IME), Rio de Janeiro, 1993.

VILLMANN, T., MERÉNYI, E. Extensions and Modifications of SOM and its Application in Satellite Remote Sensing Processing. *Proceedings of International Computer Science Conventions Symposium on Neural Computation (NC'2000)*, 2.; May 23-26, 2000; Berlin, Germany; 2000.

WANG, Ying; GUO, Lei; LIANG, Nan. Improving the classification precision of spectral angle mapper algorithm. *Proceedings of the International Society for Optics and Photonics (SPIE): Remote Sensing and GIS Data Processing and Other Applications*. v. 7498. 749827MIPPR. 2009. Disponível em: <http://144.206.159.178/ft/CONF/16438554/16438633.pdf>>. Acesso em: 10 mar. 2011.

WASSERMAN, J. C. *O Impacto da Mobilização Química de Metais durante um Serviço de Dragagem na Baía de Sepetiba para o Terminal Marítimo da CSA*. [base de dados na Internet] Biblioteca Virtual da UFF – Universidade Federal Fluminense. Rede UFF de meio Ambiente e Desenvolvimento Sustentável – REMADS-UFF. Setembro de 2005. Disponível em: < <http://www.uff.br/remadsuff/BibVirtual/RelatdragagemCSA%20-%20Sepetiba.pdf> >. Acesso em: 03 mar. 2012.

WEBER, L. S. *Integração de dados espectrais e indicadores meteorológicos por meio de redes neurais para a estimativa de produtividade de cana-de-açúcar*. [base de dados na Internet] 2005. 128 p. Tese (Doutorado em Engenharia Agrícola) – Faculdade de Engenharia Agrícola; Universidade Estadual de Campinas; Campinas. 2005. Disponível em: <http://www.bibliotecadigital.unicamp.br/document/?down=vtls000445899>>. Acesso em dez. 2009.

ZHANG, J., KIRBY, R. P. An evaluation of fuzzy approaches to mapping land cover from aerial photographs. *International Society for Photogrammetry and Remote Sensing (ISPRS). Journal of Photogrammetry & Remote Sensing*. n. 52. p. 193-201. 1997.

ZHANG, J.; STUART, N. Fuzzy methods for categorical mapping with image-based land cover data. *International Journal of Geographical Information Science*. v. 15, n. 2. p. 175-195. 2001. Disponível em: http://lab.geog.ntu.edu.tw/course/gisluc/GIS_Paper/classification.pdf>. Acesso em: 10 mar. 2011.

ZHAO, X.; CHEN, X.; STEIN, A. Integrating multi - source information via fuzzy classification method for wetland grass mapping. *Proceedings of International Society for Photogrammetry and Remote Sensing (ISPRS 2008)*, 21.; Silk road for information from imagery; 3-11 July; Beijing, China; 2008. p. 1463-1470. Disponível em: http://www.isprs.org/proceedings/XXXVII/congress/7_pdf/9_ThS-17/11.pdf >. Acesso em: 02 mar. 2009.

BIBLIOGRAFIA

AZEVEDO, Fernando M.; BRASIL, Lourdes M.; OLIVEIRA, R. C. L. de. *Redes Neurais com Aplicações em Controle e em Sistemas Especialistas*. 1. ed. Florianópolis: Visual Books, 2000. 401 p.

CÂMARA, Gilberto; MEDEIROS, José Simeão de. *Geoprocessamento para Projetos Ambientais*. [base de dados na Internet] Tutorial da Divisão de Processamento de Imagens. Instituto de Pesquisas Espaciais (INPE). INPE-8568-PRE/4312. São José dos Campos: INPE, 2001. 37 p. Disponível em: <<http://mtc-m12.sid.inpe.br/col/sid.inpe.br/sergio/2004/04.19.15.08/doc/cap10-aplicacoesambientais.pdf>>. Acesso em: 07 set. 2008.

DIB, Simone F. (Coordenadora). *Roteiro para Apresentação das Teses e Dissertações da Universidade do Estado do Rio de Janeiro*. Rio de Janeiro: UERJ, Rede Sirius, 2007. 133 p. Disponível em: <http://www.bdtd.uerj.br/roteiro_uerj_web.pdf>. Acesso em: 14 out. 2008.

HÖPPNER, F.; KLAWONN, F.; KRUSE, R.; RUNKLER, T. *Fuzzy Cluster Analysis: Methods for classification, data analysis and image recognition*. Reprinted. New York, NY: John Wiley & Sons, 2000. 288p.

JENSEN, J. R. *Introductory Digital Image Processing: A Remote Sensing Perspective*. 3. ed. USA, New Jersey: Prentice Hall, Inc., 2004. 544 p.

KUNCHEVA, L. I. *Combining Pattern Classifiers: Methods and Algorithms*. Hoboken, New Jersey: Wiley-Interscience, 2004. 360 p.

OGIELA, M. R.; JAIN, L.C. (Eds.). *Computational Intelligence Paradigms in Advanced Pattern Classification*. Studies in Computational Intelligence, Vol. 386. Berlin, Germany: Springer-Verlag, 2012. 213 p.

REEBER, Robert G.(Ed). *Manual of Remote Sensing*. 2. v. The American Society of Photogrammetry. USA: Falls Church Virginia, 1975.

ROKACH, L. *Pattern Classification using Ensemble Methods*. Series in Machine Perception and Artificial Intelligence. H. Bunke, P. S. P. Wang (Editors). v. 75. Singapore: World Scientific, 2010. 237 p.

APÊNDICE A – Classificações da especialista em imagem




Figura 41 - Imagem da classificação da especialista para o recorte 1A – Guaratiba da área-teste.




Figura 42 - Imagem da classificação da especialista para o recorte 1B – Mangaratiba da área-teste.




Figura 43 - Imagem da classificação da especialista para o recorte 1C – Magé da área-teste.

APÊNDICE B – Classificações do sistema IDRISI Taiga




Figura 44 - Imagem da classificação realizada pela função CLUSTER no IDRISI para o recorte 1A – Guaratiba da área-teste.

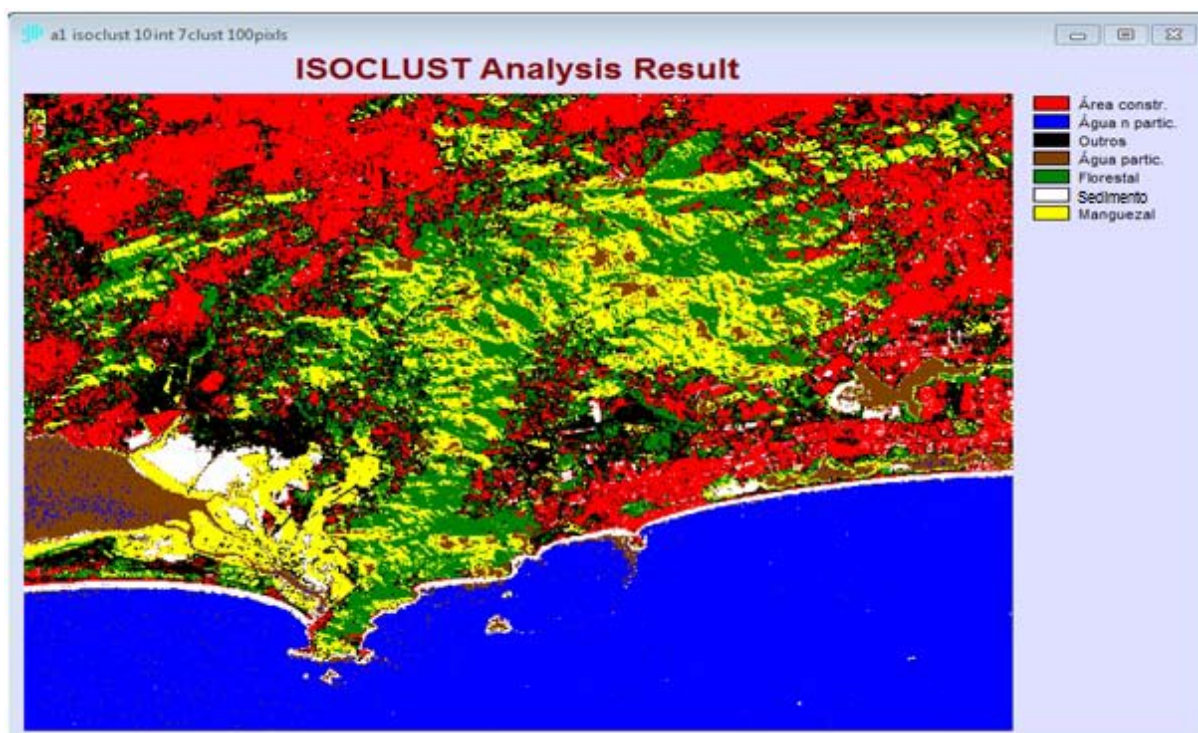


Figura 45 - Imagem da classificação realizada pela função ISOCLUST no IDRISI para o recorte 1A – Guaratiba da área-teste.




Figura 46 - Imagem da classificação realizada pela função CLUSTER no IDRISI para o recorte 1B – Mangaratiba da área-teste.

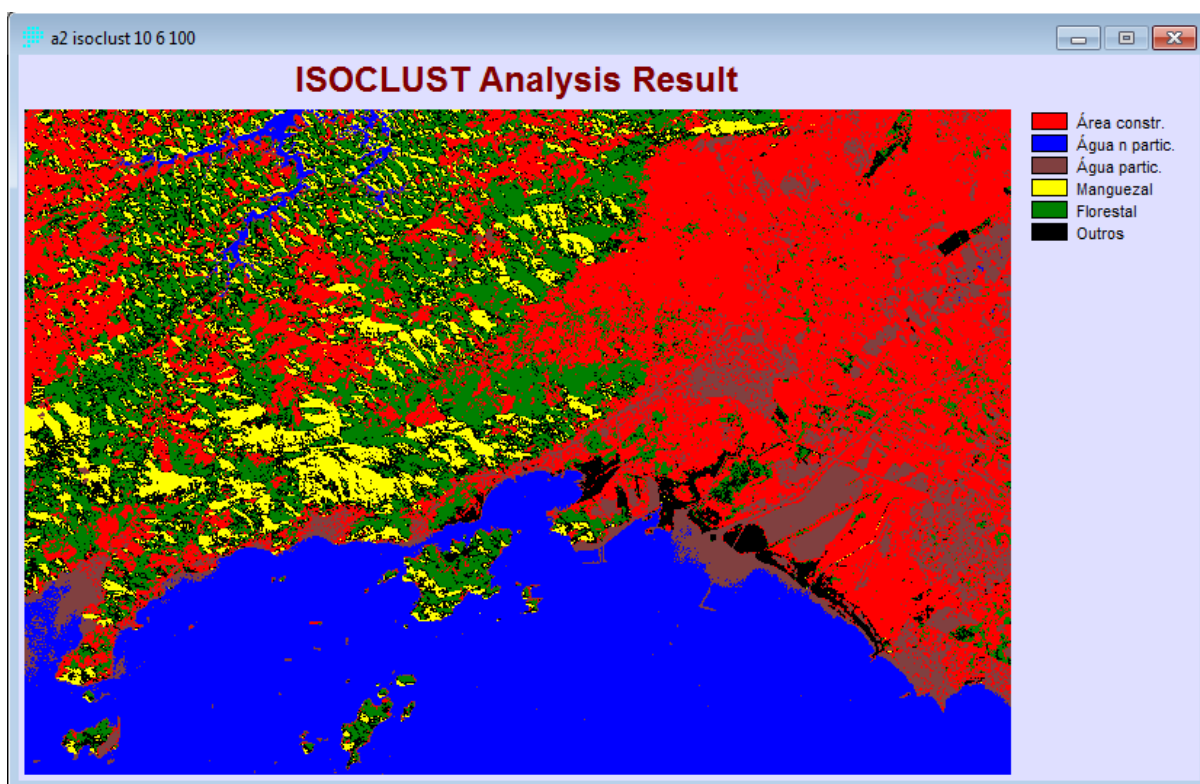


Figura 47 - Imagem da classificação realizada pela função ISOCLUST no IDRISI para o recorte 1B – Mangaratiba da área-teste.

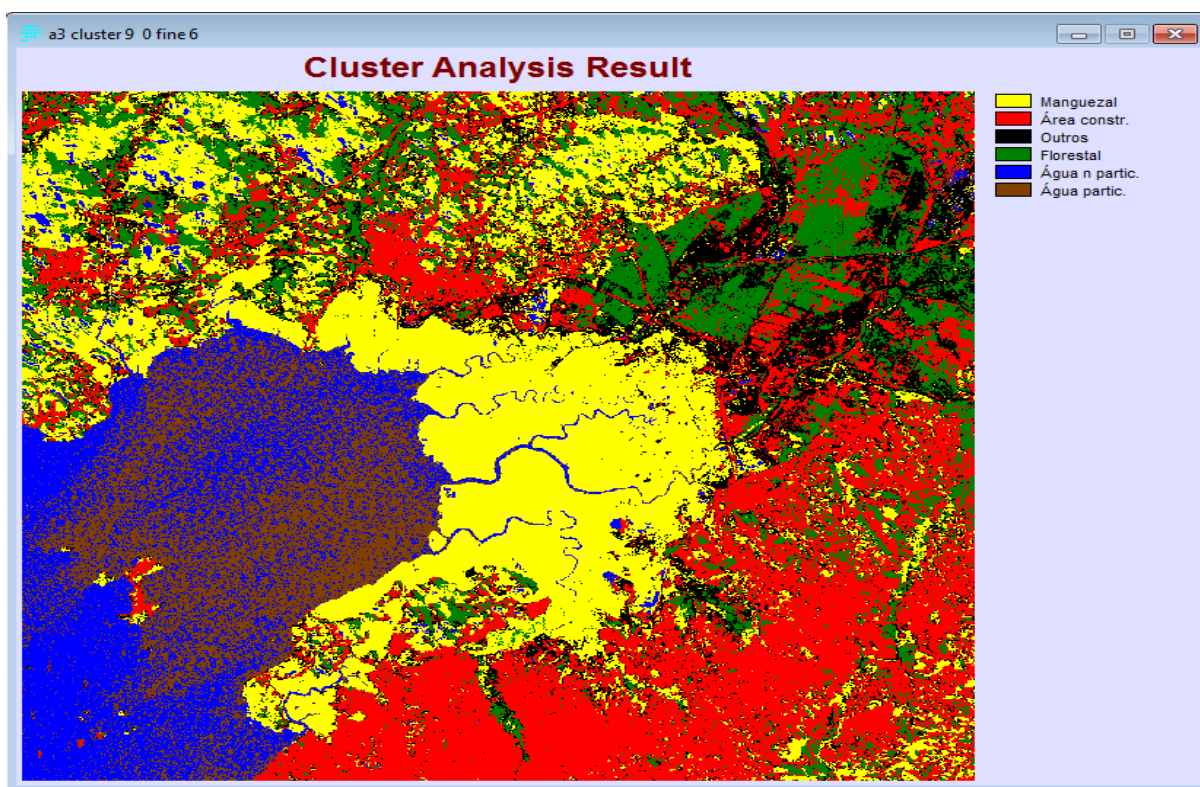


Figura 48 - Imagem da classificação realizada pela função CLUSTER no IDRISI para o recorte 1C – Magé da área-teste.

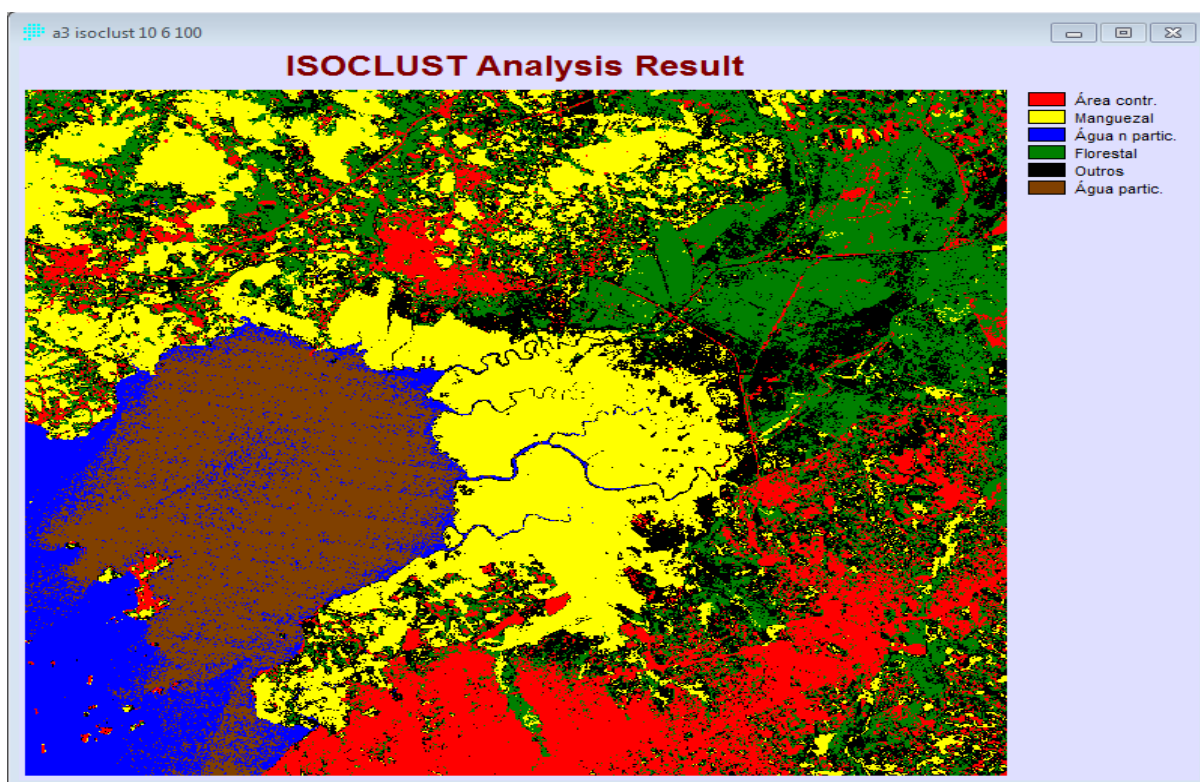


Figura 49 - Imagem da classificação realizada pela função ISOCLUST no IDRISI para o recorte 1C – Magé da área-teste.

APÊNDICE C – Classificações do sistema ENVI




Figura 50 - Imagem da classificação do ISODATA pelo ENVI para o recorte 1A – Guaratiba da área-teste.




Figura 51 - Imagem da classificação da K-MEANS pelo ENVI para o recorte 1A – Guaratiba da área-teste.




Figura 52 - Imagem da classificação do ISODATA pelo ENVI para o recorte 1B – Mangaratiba da área-teste.




Figura 53 – Imagem da classificação do K-MEANS pelo ENVI para o recorte 1B – Mangaratiba da área-teste.




Figura 54 - Imagem da classificação do ISODATA pelo ENVI para o recorte 1C – Magé da área-teste.




Figura 55 – Imagem da classificação do K-MEANS pelo ENVI no recorte 1C – Magé da área-teste.

APÊNDICE D – Classificações do integrador




Figura 56 - Classificação do recorte 1A – Guaratiba pelo integrador.




Figura 57 - Classificação do recorte 1B – Mangaratiba pelo integrador.




Figura 58 - Classificação do recorte 1C – Magé pelo integrador.