

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO
E METEOROLOGIA - CEPSRM
CURSO DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

**AVALIAÇÃO DO DESEMPENHO DE
CLASSIFICADORES NEURAIIS
PARA APLICAÇÕES EM SENSORIAMENTO REMOTO**

por

VIVIANE TODT

Porto Alegre, RS
Junho de 1998

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO
E METEOROLOGIA - CEPSRM
CURSO DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

**AVALIAÇÃO DO DESEMPENHO DE
CLASSIFICADORES NEURAIIS
PARA APLICAÇÕES EM SENSORIAMENTO REMOTO**

VIVIANE TODT

Bacharel em Informática

Orientador : Prof. Dr. Paulo M. Engel
Co-Orientador : Prof. Dr. Pedro A. Madruga

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre em Sensoriamento Remoto, áreas de concentração em Redes Neurais Artificiais e Engenharia Florestal.

Porto Alegre, RS
Junho de 1998

Todt, Viviane

AVALIAÇÃO DO DESEMPENHO DE CLASSIFICADORES NEURAIIS PARA APLICAÇÕES EM SENSORIAMENTO REMOTO./

Viviane Todt - Porto Alegre: UFRGS, 1998. 230 páginas.

Dissertação (Mestrado) - Universidade Federal do Rio Grande do Sul. Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia - Área de Redes Neurais Artificiais aplicada ao Sensoriamento Remoto. Porto Alegre, 1998.

1. Redes Neurais Artificiais
2. Sensoriamento Remoto
3. Engenharia Florestal

“Façam também uma arca de madeira de acácia. Terá de ser revestida de ouro puro, por dentro e por fora...” (Êx 25:10,11)
“Na arca estarão as leis que dão testemunho de minha aliança. Ali darei a você os meus mandamentos para o povo de Israel.” (Êx 25:22)

À Deus, Onde busquei a força necessária para
completar mais esta etapa da minha vida.

PÓSTUMAS

À minha querida avó Nilza Ramos de Oliveira
À minha querida madrinha Vânia Ramos Brambilla

Saudades

AGRADECIMENTOS

Gostaria de agradecer e, ao mesmo tempo, dedicar este trabalho a todos que contribuíram para sua realização e que, sobretudo, tornaram-se meus amigos.

Meu muito obrigada:

Ao Prof. Dr. Paulo Engel pela orientação, amizade, confiança e oportunidade de crescimento profissional.

Ao Prof. Dr. Pedro Madruga pela orientação e amizade.

Ao Prof. Dr. Flávio Deppe pelo auxílio indispensável durante todo este trabalho.

A Prof.^a Dr. Denise Fontana pelo material didático e contribuição na revisão do texto.

Aos professores Vitor Haertel, Robin T. Clarke e Jorge Ducati, pelos ensinamentos, que vieram a ser muito úteis na realização deste estudo, e por estarem sempre prontos a ajudar.

Aos funcionários do CEPSRM, em especial a Magdalena, Laurindo, Mônica, Luciane e Fabiana, que sempre se mostraram prestativos para comigo.

Aos meus colegas do CEPSRM, Marcos, Cleber, Mazzuca, Alexandre, Glauco, Márcio, Marcelo e Rose, pela amizade.

A Luciano Watzlawick Farinha pelo material didático e pela grande ajuda na realização do trabalho de campo.

A Rodrigo Vanini pela paciência, amizade e auxílio no funcionamento das Redes Neurais.

A Eduardo Todt pela amizade, carinho e contribuição na revisão do texto.

A Fernanda K. Denardin pela ajuda com as referências bibliográficas e pela amizade.

A Mauro Steigleder pela amizade e ajuda com a visualização das amostras.

A dois grandes amigos e colegas: Neide Pizzolato e Sérgio Florêncio.

A Vangie M. R. de Oliveira e aos meus irmãos, Anelise e Fabiano, a quem muito estimo, por todo o apoio, amizade e carinho.

A toda minha família, em especial aos meus pais, Henrique e Vanessa, a quem muito amo e que sempre me auxiliaram e apoiaram.

A Tiarajú A. Diverio pela compreensão, paciência, amor e por toda a alegria que tem proporcionado em minha vida.

Também, gostaria de agradecer:

Ao Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, da UFRGS, pela oportunidade.

Ao Instituto de Informática, da UFRGS, por disponibilizar os equipamentos necessários ao desenvolvimento deste trabalho, em especial, a Kika, Margarete e Ida (pela ajuda indispensável na revisão bibliográfica).

A Empresa Riocell por ceder o uso das imagens de satélite (em especial, a Leonísio Posser por sua contribuição no mapeamento de algumas *imagettes*).

A CAPES pelo apoio financeiro indispensável à realização deste trabalho.

**AValiação DO DESEMPENHO DE
CLASSIFICADORES NEURais
PARA APLICAÇÕES EM SENSORIAMENTO REMOTO¹**

AUTOR: VIVIANE TODT

ORIENTADOR: PROF. DR. PAULO MARTINS ENGEL

CO-ORIENTADOR: PROF. DR. PEDRO A. MADRUGA

SINOPSE

Atualmente, pesquisadores das mais diversas áreas, tais como: Geologia, Física, Cartografia, Oceanografia, entre outras, utilizam imagens de satélite como uma fonte valiosa para a extração de informações sobre a superfície terrestre. Muitas vezes, a análise (classificação) destas imagens é realizada por métodos tradicionais sejam eles supervisionados (como o Método de Máxima Verossimilhança Gaussiana) ou não-supervisionados (como o Método de Seleção pelo Pico do Histograma). Entretanto, pode-se utilizar as Redes Neurais Artificiais como uma alternativa para o aumento da acurácia em classificações digitais. Neste trabalho, utilizou-se imagens multi-espectrais do satélite *LANDSAT 5-TM* para a identificação de espécies vegetais (Mata Nativa, *Eucalyptus* e *Acácia*) em uma região próxima aos municípios de General Câmara, Santo Amaro e Taquari, no Estado do Rio Grande do Sul, Brasil. Comparou-se qualitativamente e quantitativamente os resultados obtidos pelo método de Máxima Verossimilhança Gaussiana e por uma Rede Neural Artificial Multinível com *BackPropagation* na classificação da área de estudo. Para tanto, parte desta área foi mapeada através de uma verificação de campo e com o auxílio de classificadores não-supervisionados (*Kohonen*, que é uma Rede Neural, e o método de Seleção pelo Pico do Histograma). Com isto, foi possível coletar dois conjuntos de amostras, sendo que um deles foi utilizado para o treinamento dos métodos e o outro (conjunto de reconhecimento) serviu para a avaliação das classificações obtidas. Após o treinamento, parte da área de estudo foi classificada por ambos os métodos. Em seguida, os resultados obtidos foram avaliados através do uso de Tabelas de Contingência, considerando um nível de significância de 5%. Por fim, na maior parte dos testes realizados, a Rede Neural Artificial Multinível com *BackPropagation* apresentou valores de acurácia superiores ao Método de Máxima Verossimilhança Gaussiana. Assim, com este trabalho observou-se que não há diferença significativa de classificação para as espécies vegetais, ao nível de 5%, para a área de estudo considerada, na época de aquisição da imagem, para o conjunto de reconhecimento.

¹Dissertação de Mestrado em Sensoriamento Remoto, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Curso de Pós-graduação em Sensoriamento Remoto da Universidade Federal do Rio Grande do Sul, Porto Alegre/RS (232 p.), Junho de 1998.

PERFORMANCE EVALUATION OF NEURAL CLASSIFIERS FOR REMOTE SENSING APPLICATIONS ²

AUTHOR: VIVIANE TODT

ADVISOR: PROF. DR. PAULO MARTINS ENGEL

CO-ADVISOR: PROF. DR. PEDRO A. MADRUGA

ABSTRACT

Nowadays, researchers of different areas such as Geology, Physics, Mapping, and Oceanography, among others, make use of satellite images as a valuable source for the information extract about the surface of the Earth. Many times the analysis (classification) of this image is made through supervised traditional methods (as the Gaussian Maximum Likelihood Method) or non-supervised (as the Peak Histogram Selection). However, Artificial Neural Network can be used as an alternative to the accuracy rise in digital classifications. In this work, it has made use of multispectral images of the satellite *LANDSAT 5-TM* for the vegetal species identification (Native Forest, *Eucalyptus*, and *Acacia*) in a region near the cities of General Câmara, Santo Amaro, and Taquari, in Rio Grande do Sul, Brazil. It has been made a qualitative and quantitative comparison of the results obtained through the Gaussian Maximum Likelihood Method as much as a Back-Propagation Neural Network in the classification of the study's area. In this manner, part of this area was mapped through a field verification with the aid of non-supervised classifiers (Kohonen, which is a Neural Network, and the Peak Histogram Selection). Thus, it was possible to collect two sample sets, one of them was used for the method training and the other one (recognition set) was used to the evaluation of the classifications obtained. After the training, part of the study's area was classified for both methods. Soon, the results obtained were evaluated through the use of Contingency Tables, considering a significance level of 5%. Ending, in the most part of the test, the Back-Propagation Neural Network has presented values of superior accuracy to the Gaussian Maximum Likelihood Method. So, through this work, it was observed that there is not significative difference of classification for the vegetal species, level of 5%, for the study's area considered in the image acquisition time, for the recognition set.

²Master of Science Thesis, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Graduate Course in Remote Sensing, Universidade Federal do Rio Grande do Sul. Porto Alegre/RS, (232 p.) - June, 1998.

SUMÁRIO

LISTA DE TABELAS	xii
LISTA DE FIGURAS	xiv
LISTA DE ANEXOS	xvii
LISTA DE ABREVIATURAS	xviii
LISTA DE SÍMBOLOS	xix
LISTA DE FÓRMULAS	xxi
1 INTRODUÇÃO.....	1
2 REVISÃO BIBLIOGRÁFICA.....	4
2.1 Classificação de imagens digitais	4
2.2 Métodos tradicionais.....	10
2.2.1 Clusterização pelo Pico do Histograma	10
2.2.1.1 Características	10
2.2.1.2 Funcionamento.....	10
2.2.1.3 Considerações gerais.....	11
2.2.2 Máxima Verossimilhança Gaussiana	12
2.2.2.1 Características	12
2.2.2.2 Funcionamento.....	13
2.2.2.3 Considerações gerais.....	16
2.3 Redes Neurais Artificiais	18
2.3.1 Mapas de Kohonen	19
2.3.1.1 Características do modelo	19
2.3.1.2 Funcionamento	22
2.3.1.3 Considerações gerais.....	25
2.3.2 Rede Neural Multinível com BackPropagation.....	28
2.3.2.1 Características do modelo	28
2.3.2.2 Algoritmo BackPropagation.....	29
2.3.2.3 Considerações gerais.....	34
2.4 Máxima Verossimilhança Gaussiana versus Redes Neurais	36
2.5 Geo-referenciamento	39
2.5.1 O que é?	39
2.5.2 Considerações.....	43
2.6 Comportamento espectral da vegetação	45
2.6.1 Estrutura de uma folha típica	45
2.6.2 Comportamento espectral de uma folha individual.....	47
2.6.3 Comportamento espectral de uma comunidade vegetal.....	50
2.6.4 Seleção de bandas do LANDSAT 5-TM para estudo da vegetação	53
3 ÁREA DE ESTUDO	55
3.1 Localização e descrição.....	55
3.2 Espécies vegetais.....	57
3.2.1 Eucalyptus	58
3.2.1.1 Origem	58
3.2.1.2 Características	58
3.2.1.3 Espécies.....	58
3.2.1.4 Uso	59
3.2.1.5 Pragas florestais	59
3.2.1.6 Importância	60
3.2.2 Acácia	60
3.2.2.1 Origem	60

3.2.2.2	Características	60
3.2.2.3	Espécies.....	61
3.2.2.4	Uso	61
3.2.2.5	Pragas florestais	62
3.2.2.6	Importância	62
3.2.3	Nativas.....	62
3.2.3.1	Características	62
3.2.3.2	Espécies.....	62
3.2.3.3	Uso	64
3.2.3.4	Pragas florestais	64
3.2.3.5	Considerações	65
3.3	Descrição das classes.....	65
3.3.1	Nativa	65
3.3.2	<i>Eucalyptus</i>	66
3.3.3	<i>Acácia</i>	66
3.3.4	Pastagem	66
3.3.5	Solo exposto	67
3.3.6	Água	67
3.3.7	Desconhecida	67
4	MATERIAIS UTILIZADOS	68
5	METODOLOGIA	70
5.1	Geo-referenciamento	70
5.2	Verificação de campo.....	73
5.2.1	Confecção de material	74
5.2.1.1	<i>Imagettes</i>	74
5.2.1.2	Formulários	74
5.2.1.3	Tabela de classificação.....	74
5.2.1.4	Estradas digitalizadas.....	76
5.2.1.5	Imagem Porto Alegre-área de estudo.....	77
5.2.2	Estabelecimento do trajeto.....	77
5.2.3	Mapeamento das <i>Imagettes</i>	77
5.3	Seleção de bandas.....	78
5.4	<i>Clusterização</i>	78
5.4.1	Método tradicional.....	78
5.4.2	<i>Kohonen</i>	79
5.5	Classificação supervisionada.....	80
5.5.1	Coleta de amostras.....	80
5.5.2	Máxima Verossimilhança Gaussiana	82
5.5.3	Rede Neural Multinível com <i>BackPropagation</i>.....	83
5.6	Aplicação do método estatístico	84
6	RESULTADOS	92
7	DISCUSSÃO.....	128
8	CONCLUSÕES GERAIS E SUGESTÕES	134
	BIBLIOGRAFIA.....	137
	ANEXOS.....	140

LISTA DE TABELAS

Tabela I	Métodos de <i>clusterização</i> . Fonte: RICHARDS (1986).....	8
Tabela II	Métodos de classificação supervisionados. Fonte: RICHARDS (1986), JENSEN (1986), CRÓSTA (1992).....	9
Tabela III	Bandas do <i>LANDSAT 5-TM</i> e suas aplicações. Fonte: NOVO (1989).....	54
Tabela IV	Distribuição de áreas por espécie na micro-região 315. Fonte: IBDF (1983)	57
Tabela V	Principais espécies nativas encontradas na região Depressão Central. Fonte: REITZ (1988).....	63
Tabela VI	Pontos de controle obtidos.....	71
Tabela VII	Tabela de classificação adotada.....	76
Tabela VIII	Distribuição de amostras/dia.....	77
Tabela IX	<i>Clusterizações</i> pelo método do Histograma Tridimensional	78
Tabela X	<i>Clusterizações</i> por <i>Kohonen</i>	79
Tabela XI	Conjunto de treinamento (número de <i>pixels</i> /classe)	81
Tabela XII	Classificações por MAXVER.....	82
Tabela XIII	Classificações pela Rede Neural Multinível com <i>BackPropagation</i>	83
Tabela XIV	Quantidade de <i>pixels</i> /classe utilizados no conjunto de treinamento e de reconhecimento.....	84
Tabela XV	Acertos obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de treinamento (em porcentagem)	86
Tabela XVI	Distribuição de erros obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de treinamento (em porcentagem)	86
Tabela XVII	Acertos obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de reconhecimento (em porcentagem)	87
Tabela XVIII	Distribuição de erros obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de reconhecimento (em porcentagem).....	87
Tabela XIX	Acertos obtidos pela Rede Neural Multinível com <i>BackPropagation</i> para o conjunto de treinamento (em porcentagem)	88
Tabela XX	Distribuição de erros obtidos pela Rede Neural Multinível com <i>BackPropagation</i> para o conjunto de treinamento (em porcentagem)	88
Tabela XXI	Acertos obtidos pela Rede Neural Multinível com <i>BackPropagation</i> para o conjunto de reconhecimento (em porcentagem)	89

Tabela XXII	Distribuição de erros obtidos pela Rede Neural Multinível com <i>BackPropagation</i> para o conjunto de reconhecimento (em porcentagem)	89
Tabela XXIII	Teste 01 (bandas 123457). Conjunto de treinamento.....	116
Tabela XXIV	Teste 02 (bandas 12345). Conjunto de treinamento.....	117
Tabela XXV	Teste 03 (bandas 13457). Conjunto de treinamento.....	118
Tabela XXVI	Teste 04 (bandas 12457). Conjunto de treinamento.....	119
Tabela XXVII	Teste 05 (bandas 12347). Conjunto de treinamento.....	120
Tabela XXVIII	Teste 06 (bandas 23457). Conjunto de treinamento.....	121
Tabela XXIX	Teste 01 (bandas 123457). Conjunto de reconhecimento	122
Tabela XXX	Teste 02 (bandas 12345). Conjunto de reconhecimento	123
Tabela XXXI	Teste 03 (bandas 13457). Conjunto de reconhecimento	124
Tabela XXXII	Teste 04 (bandas 12457). Conjunto de reconhecimento	125
Tabela XXXIII	Teste 05 (bandas 12347). Conjunto de reconhecimento	126
Tabela XXXIV	Teste 06 (bandas 23457). Conjunto de reconhecimento	127

LISTA DE FIGURAS

Figura 2.1	Imagem multi-espectral. Adaptação: JENSEN (1986).....	4
Figura 2.2	Classes e subclasses no espaço bidimensional. Adaptação: RICHARDS (1986).....	6
Figura 2.3	Avaliação de picos em um histograma bidimensional.....	11
Figura 2.4	Uso de <i>threshold</i>	16
Figura 2.5	Neurônio. Adaptação: FREEMAN & SKAPURA (1991).....	18
Figura 2.6	Processo de estimulação de neurônios do cérebro. Adaptação: NUNES (1995).....	20
Figura 2.7	Exemplo de topologia de uma rede de <i>Kohonen</i> . Adaptação: NUNES (1995).....	20
Figura 2.8	Pesos e entradas em um espaço bidimensional. Adaptação: NUNES (1995).....	21
Figura 2.9	Comportamento do coeficiente de aprendizado.....	23
Figura 2.10	Exemplo de determinação da vizinhança discreta em torno do neurônio vencedor 13. Adaptação: KOHONEN (1989).....	24
Figura 2.11	Rede hipotética (9 neurônios, 2 entradas). Adaptação: NUNES (1995).....	26
Figura 2.12	Rede não treinada (9 neurônios, 2 entradas) com pesos inicializados com valores aleatórios.....	27
Figura 2.13	(a) Rede sendo treinada (b) Rede treinada (9 neurônios, 2 entradas). Adaptação: KOHONEN (1989).....	27
Figura 2.14	Topologia de uma RNA Multinível com <i>BackPropagation</i> . Adaptação: FREEMAN & SKAPURA (1991).....	28
Figura 2.15	Função Sigmoidal.....	30
Figura 2.16	Função Tangente Hiperbólica.....	31
Figura 2.17	Funcionamento dos neurônios da camada escondida. Fase de propagação. Adaptação: FREEMAN & SKAPURA (1991).....	31
Figura 2.18	Funcionamento dos neurônios da camada de saída. Fase de propagação. Adaptação: FREEMAN & SKAPURA (1991).....	32
Figura 2.19	Exemplo de pares de pontos de controle. Adaptação: EASTMAN (1996).....	40
Figura 2.20	Exemplo de geo-referenciamento (imagem x mapa). Adaptação: JENSEN (1986).....	42
Figura 2.21	Estrutura interna de uma folha típica. Fonte: ASSUNÇÃO & FORMAGGIO (1989).....	46

Figura 2.22	Comportamento espectral de uma folha individual. Fonte: ASSUNÇÃO & FORMAGGIO (1989)	47
Figura 2.23	Efeito de diferentes pigmentos no comportamento espectral de folhas de coleus. Fonte: SWAIN & DAVIS (1978)	49
Figura 2.24	Efeito do teor de umidade no comportamento espectral de folhas de feijão. Fonte: ASSUNÇÃO & FORMAGGIO (1989).....	49
Figura 2.25	Processo de Reflectância Aditiva. Fonte: ASSUNÇÃO & FORMAGGIO (1989)	51
Figura 2.26	Relação entre as faixas espectrais dos sensores <i>LANDSAT TM</i> e <i>LANDSAT MSS</i> e a reflectância espectral de alvos da superfície terrestre. Adaptação: RICHARDS (1986)	52
Figura 3.1	Localização da área de estudo. Adaptação: DEPPE (1995)	55
Figura 3.2	Área de estudo. Composição colorida em RGB. Bandas 432.....	56
Figura 5.1	Etapas e ordem de execução	70
Figura 5.2	Área de estudo geo-referenciada.....	71
Figura 5.3	Informações para o Geo-referenciamento.....	72
Figura 5.4	Área de estudo dividida em áreas amostrais	74
Figura 5.5	Áreas amostrais selecionadas.....	75
Figura 5.6	Estradas e caminhos na área de estudo	76
Figura 5.7	Assinaturas espectrais das classes pré-definidas.....	81
Figura 6.1	<i>Clusterização</i> das áreas amostrais pelo método do Histograma Tridimensional. Bandas 345.	93
Figura 6.2	<i>Clusterização</i> das áreas amostrais pelo método do Histograma Tridimensional. Bandas 347.	94
Figura 6.3	<i>Clusterização</i> das áreas amostrais por <i>Kohonen</i> . Bandas 345.....	95
Figura 6.4	<i>Clusterização</i> das áreas amostrais por <i>Kohonen</i> . Bandas 23457	96
Figura 6.5	<i>Clusterização</i> das áreas amostrais por <i>Kohonen</i> . Bandas 123457	97
Figura 6.6	Classificação por MAXVER. Bandas 123457.....	98
Figura 6.7	Classificação por MAXVER. Bandas 12345.....	99
Figura 6.8	Classificação por MAXVER. Bandas 13457.....	100
Figura 6.9	Classificação por MAXVER. Bandas 12457.....	101

Figura 6.10	Classificação por MAXVER. Bandas 12347.....	102
Figura 6.11	Classificação por MAXVER. Bandas 23457.....	103
Figura 6.12	Classificação pela RNA. Bandas 123457.....	104
Figura 6.13	Classificação pela RNA. Bandas 12345.....	105
Figura 6.14	Classificação pela RNA. Bandas 13457.....	106
Figura 6.15	Classificação pela RNA. Bandas 12457.....	107
Figura 6.16	Classificação pela RNA. Bandas 12347.....	108
Figura 6.17	Classificação pela RNA. Bandas 23457.....	109
Figura 6.18	Acurácia obtida para a classe Nativa (conjunto de treinamento).....	110
Figura 6.19	Acurácia obtida para a classe <i>Eucalyptus</i> (conjunto de treinamento).....	110
Figura 6.20	Acurácia obtida para a classe <i>Acácia</i> (conjunto de treinamento).....	111
Figura 6.21	Acurácia obtida para a classe Pastagem (conjunto de treinamento).....	111
Figura 6.22	Acurácia obtida para a classe Solo (conjunto de treinamento).....	112
Figura 6.23	Acurácia obtida para a classe Água (conjunto de treinamento).....	112
Figura 6.24	Acurácia obtida para a classe Nativa (conjunto de reconhecimento).....	113
Figura 6.25	Acurácia obtida para a classe <i>Eucalyptus</i> (conjunto de reconhecimento).....	113
Figura 6.26	Acurácia obtida para a classe <i>Acácia</i> (conjunto de reconhecimento).....	114
Figura 6.27	Acurácia obtida para a classe Pastagem (conjunto de reconhecimento).....	114
Figura 6.28	Acurácia obtida para a classe Solo (conjunto de reconhecimento).....	115
Figura 6.29	Acurácia obtida para a classe Água (conjunto de reconhecimento).....	115

LISTA DE ANEXOS

Anexo 01	Lista de Figuras e Tabelas dos Anexos	138
Anexo 02	Princípios básicos de Sensoriamento Remoto.....	142
Anexo 03	Características do sistema <i>LANDSAT</i>	146
Anexo 04	Regiões Fisiográficas do Rio Grande do Sul. Fonte: IBDF (1983).....	149
Anexo 05	Micro-Regiões do Rio Grande do Sul. Fonte: IBDF (1983)	150
Anexo 06	Área de estudo em relação à capital metropolitana	151
Anexo 07	Amostras para o treinamento dos classificadores supervisionados	152
Anexo 08	Resultados obtidos com o Geo-referenciamento.....	153
Anexo 09	Histograma das classes/banda	154
Anexo 10	Áreas amostrais (<i>imagettes</i>) e seus respectivos formulários	166
Anexo 11	Listagem do programa que gera números aleatórios entre 0 e 99 (NUMALE.C).....	201
Anexo 12	Listagem do programa que implementa a RNA Multinível com BP (BPTANH.C)	203
Anexo 13	Listagem do programa que calcula a quantidade de acertos e erros em imagens classificadas (ACURACIA.C)	221
Anexo 14	Seleção de bandas (Distância de <i>Bhattacharyya</i>).....	224
Anexo 15	Acertos e erros obtidos pelo método de Máxima Verossimilhança Gaussiana e pela Rede Neural Multinível com <i>BackPropagation</i>	226

LISTA DE ABREVIATURAS

BP	<i>BackPropagation</i>
DSG	Diretoria de Serviço Geográfico
ERTS-1	<i>Earth Resources Technology Satellite -1</i>
GPS	<i>Global Position System</i>
IBDF	Instituto Brasileiro de Desenvolvimento Florestal
INPE	Instituto Nacional de Pesquisas Espaciais
IRENE	Implementação de Redes Neurais
IV	Infravermelho
LMS	<i>Least Mean Square Error</i>
LVQ	<i>Linear Vector Quantization</i>
MAXVER	Máxima Verossimilhança
MSS	<i>Multispectral Scanner Subsystem</i>
NASA	<i>National Aeronautics and Space Administration</i>
RBV	<i>Return Beam Vidicom</i>
RNA	Rede Neural Artificial
SITIM	Sistema de Tratamento de Imagens
SR	Sensoriamento Remoto
TM	<i>Thematic Mapper</i>
UTM	<i>Universal Transversa Mercator</i>

LISTA DE SÍMBOLOS

λ	Comprimento de onda
μm	Micrômetro
χ^2	Qui-quadrado
gl	Grau de liberdade
W_i	Classe i
$P(W_i)$	Probabilidade de ocorrência da classe W_i
$P(X)$	Probabilidade de encontrar um <i>pixel</i> de qualquer classe na posição X
$P(W_i/X)$	Probabilidade do <i>pixel</i> X pertencer a classe W_i
$P(X/W_i)$	Probabilidade interna da classe i
exp	Função exponencial
ln	Logaritmo neperiano (natural)
Σ	Somatório
Σ_i	Matriz de Covariância da classe i
μ_i	Vetor médio da classe i
$G_i(X)$	Função de discriminação para a classe i
T_i	<i>Threshold</i> para classe i
Y_j	Saída do neurônio j
Y_{pk}	Saída desejada para o padrão p
O_{pk}	Saída obtida para o padrão p
X_p	Vetor de entrada do padrão p
X_{pi}	Vetor de entrada do padrão p para o neurônio i
W_{ji}	Peso entre os neurônios j e i
W_{ji}^h	Peso entre os neurônios j e i da camada escondida
t	Iteração atual
t_{max}	Número máximo de iterações
$\alpha(t)$	Coefficiente de aprendizado no tempo t para vizinhança discreta
α_0	Coefficiente de aprendizado inicial para vizinhança discreta
α_f	Coefficiente de aprendizado final para vizinhança discreta
$\delta(t)$	Coefficiente de aprendizado no tempo t para vizinhança contínua
δ_0	Coefficiente de aprendizado inicial para vizinhança contínua
δ_f	Coefficiente de aprendizado final para vizinhança contínua
d_{pj}	Distância Euclidiana entre a entrada i do padrão p e o peso do neurônio j
h_{jj}'	Vizinhança contínua
j'	Neurônio vencedor

j_c	Coordenada da coluna do neurônio j (posição física dentro do mapa de <i>Kohonen</i>)
j_l	Coordenada da linha do neurônio j (posição física dentro do mapa de <i>Kohonen</i>)
f	Função de ativação (Sigmoidal ou Tangente Hiperbólica)
f'	Derivada da função de ativação
$\text{sigm}(x)$	Função Sigmoidal
$\text{tanh}(x)$	Função Tangente Hiperbólica
$\text{sigm}'(x)$	Derivada da função Sigmoidal
$\text{tanh}'(x)$	Derivada da função Tangente Hiperbólica
net_{pj}^h	Valor interno do neurônio j da camada escondida para o padrão p
net_{pk}^o	Valor interno do neurônio k da camada de saída para o padrão p
θ_j^h	<i>Bias</i> para o neurônio j da camada escondida
θ_k^o	<i>Bias</i> para o neurônio k da camada de saída
i_{pj}	Ativação do neurônio j da camada escondida para o padrão p
O_{pk}	Ativação do neurônio k da camada de saída para o padrão p
φ_{pk}^o	Termo de erro para a camada de saída para o padrão p
φ_{pj}^h	Termo de erro para a camada escondida para o padrão p
η	Coefficiente de aprendizado para o algoritmo de <i>BackPropagation</i>
$\alpha\Delta_p$	Proporção da variação do peso (Técnica do Momento para o algoritmo de <i>BackPropagation</i>)
$\langle E \rangle$	Erro médio quadrado
$\langle E_p \rangle$	Erro obtido para o padrão p por todos os neurônios de saída
.	Separador de milhar (ponto final)

LISTA DE FÓRMULAS

Fórmula 2.1	Probabilidade de um determinado <i>pixel</i> X pertencer a uma classe W_i	13
Fórmula 2.2	Teorema de Bayes	13
Fórmula 2.3	Probabilidade de encontrar um <i>pixel</i> de qualquer classe na posição X	14
Fórmula 2.4	Probabilidade de um determinado <i>pixel</i> X pertencer a uma classe W_i	14
Fórmula 2.5	Eliminação do termo comum	14
Fórmula 2.6	Probabilidade de ocorrência igual para todas as classes	14
Fórmula 2.7	Distribuição normal de probabilidade	15
Fórmula 2.8	Matriz de covariância	15
Fórmula 2.9	Vetor médio.....	15
Fórmula 2.10	Logaritmo natural sobre a distribuição normal de probabilidade.....	15
Fórmula 2.11	Função de discriminação.....	15
Fórmula 2.12	Regra de decisão.....	16
Fórmula 2.13	Uso de <i>thresholds</i> na regra de decisão	17
Fórmula 2.14	Saída dos neurônios da rede	22
Fórmula 2.15	Atualização dos pesos do neurônio vencedor e dos neurônios vizinhos	23
Fórmula 2.16	Distância Euclidiana entre a entrada do padrão p e o peso do neurônio i	23
Fórmula 2.17	Coefficiente de aprendizado	23
Fórmula 2.18	Vizinhança contínua	24
Fórmula 2.19	Coefficiente de redução da vizinhança	24
Fórmula 2.20	Distância Euclidiana entre as posições físicas dos neurônios no mapa.....	25
Fórmula 2.21	Atualização dos pesos considerando uma vizinhança contínua	25
Fórmula 2.22	Valores internos dos neurônios da camada escondida	30
Fórmula 2.23	Ativação dos neurônios da camada escondida	30
Fórmula 2.24	Ativação dos neurônios da camada escondida considerando a função Sigmoidal e/ou a função Tangente Hiperbólica	31
Fórmula 2.25	Valores internos dos neurônios da camada de saída	31

Fórmula 2.26	Ativação dos neurônios da camada de saída	32
Fórmula 2.27	Termos de erro para as unidades de saída	32
Fórmula 2.28	Derivada da função Tangente Hiperbólica.....	32
Fórmula 2.29	Derivada da função Tangente Hiperbólica considerando a ativação dos neurônios de saída	32
Fórmula 2.30	Derivada da função Sigmoidal	32
Fórmula 2.31	Derivada da função Sigmoidal considerando a ativação dos neurônios de saída.....	33
Fórmula 2.32	Termos de erro para as unidades escondidas.....	33
Fórmula 2.33	Derivada da função Tangente Hiperbólica.....	33
Fórmula 2.34	Derivada da função Tangente Hiperbólica considerando a ativação dos neurônios da camada escondida	33
Fórmula 2.35	Derivada da função Sigmoidal considerando a ativação dos neurônios da camada escondida.....	33
Fórmula 2.36	Atualização dos pesos da camada de saída	33
Fórmula 2.37	Atualização dos pesos da camada escondida	33
Fórmula 2.38	Erro Médio Quadrado.....	34
Fórmula 2.39	Erro obtido com o padrão p.....	34
Fórmula 2.40	Atualização dos pesos da camada escondida considerando a Técnica do Momento	35
Fórmula 2.41	Atualização dos pesos da camada de saída considerando a Técnica do Momento	35
Fórmula 2.42	Modelo Linear	40
Fórmula 2.43	Modelo Quadrático.....	41
Fórmula 2.44	Erro Médio Quadrado.....	41
Fórmula 2.45	Distância de <i>Bhattacharyya</i>	53
Fórmula 5.1	Obtenção do Qui-quadrado	90

1 INTRODUÇÃO

Diariamente, grande parte da superfície terrestre é *imageada* por sensores a bordo de satélites como o *LANDSAT* (americano) ou o *SPOT* (francês). As imagens obtidas por estes satélites podem ser processadas em computadores e, posteriormente, analisadas para o monitoramento de áreas da superfície terrestre. Através destas imagens, pode-se identificar as diferentes classes de cobertura (vegetação, água, solo exposto, pastagem, cultivos de trigo e soja) e de uso (agrícola, florestal, industrial, urbano) da Terra.

O satélite *LANDSAT 5-TM* (série número cinco e sensor *Thematic Mapper*), fornece imagens multi-espectrais das áreas *imageadas*. Isto acontece, pois este satélite possui um conjunto de sete sensores, cada qual *imageando* a superfície terrestre em uma determinada faixa do espectro-eletromagnético.

Tradicionalmente a análise de imagens multi-espectrais é realizada por classificadores que se baseiam no Teorema de Bayes. O método de Máxima Verossimilhança Gaussiana se enquadra neste contexto. Entretanto, por volta de 1985, as Redes Neurais Artificiais (RNA's) começaram a ser utilizadas como uma opção para a classificação multi-espectral (BISCHOF et al., 1992). As RNA's, também conhecidas por Redes Neurais ou Redes de Neurônios Artificiais, pertencem à área da Ciência da Computação denominada Inteligência Artificial. Pode-se dizer que as Redes Neurais Artificiais são técnicas que, através de procedimentos matemáticos específicos (tais como: otimização discreta, minimização de erros, *clusterização* de vetores, entre outros), procuram resolver problemas complexos de maneira inteligente, ou seja, similarmente à maneira pela qual o cérebro humano resolveria.

Desta forma, surgem as seguintes questões: até que ponto os classificadores tradicionais são satisfatórios na análise de imagens multi-espectrais? As RNA's podem vir a contribuir no aumento da acurácia em classificações digitais?

Com o intuito de responder a estas questões (ou, pelo menos, em parte respondê-las), o presente trabalho tem por objetivo principal avaliar qualitativamente e quantitativamente o método de Máxima Verossimilhança Gaussiana e uma Rede Neural Artificial Multinível com *BackPropagation*. Mais precisamente, neste trabalho, avalia-se o desempenho destes classificadores na identificação de espécies vegetais (Mata Nativa, *Eucalyptus* e Acácia), em imagens multi-espectrais do satélite *LANDSAT 5-TM*.

Como objetivo específico, este trabalho averigua sobre o uso de classificadores não-supervisionados (*clusterizadores*), para a identificação das possíveis classes e subclasses existentes na área de estudo. Para tanto, o processo de *clusterização* foi realizado por uma Rede Neural Artificial conhecida por *Kohonen* e pelo método do Histograma Tridimensional (método tradicional).

A área de estudo situa-se próxima aos municípios de General Câmara, Santo Amaro e Taquari, no Estado do Rio Grande do Sul, Brasil. Esta região foi escolhida por ser significativa em termos de reflorestamento, por ser de fácil acesso e por ser de interesse às empresas de celulose, tanino, postes, energia e de madeiras de Porto Alegre (capital do estado do Rio Grande do Sul). Em termos de vegetação, pode-se caracterizá-la pela presença de Florestas Naturais (ou Nativas) e Florestas Exóticas (ou Artificiais), sendo estas últimas formadas por extensos reflorestamentos de *Eucalyptus* e *Acácia*. Esta região é banhada pelos rios Jacuí e Taquari e, além disto, apresenta uma grande quantidade de solos descobertos e pastagens.

Com os resultados da *clusterização* e da aquisição de dados de campo foi possível a obtenção de um conjunto de treinamento e outro de reconhecimento. O primeiro conjunto foi utilizado no treinamento dos classificadores supervisionados (Rede Neural Multinível com *BackPropagation* e Máxima Verossimilhança Gaussiana), enquanto que o segundo serviu para a avaliação das imagens classificadas por eles. A avaliação foi feita com o uso de Tabelas de Contingência que permitiram comparar, quantitativamente, cada imagem classificada com a verdade terrestre.

As primeiras seções deste trabalho apresentam uma revisão bibliográfica sobre as características e o funcionamento de alguns métodos de classificação supervisionados (Máxima Verossimilhança Gaussiana e Rede Neural Multinível com *BackPropagation*) e não-supervisionados (Histograma Tridimensional e *Kohonen*), sobre o geo-referenciamento de imagens de satélite (este procedimento foi necessário na localização de áreas amostrais, para a aquisição de dados de campo) e sobre o comportamento espectral da vegetação, além de citar as bandas do satélite *LANDSAT 5-TM* indicadas para o estudo de espécies vegetais. Em especial, a seção 2.4 apresenta as vantagens e desvantagens do uso do método de Máxima Verossimilhança Gaussiana e de Redes Neurais na classificação de imagens multi-espectrais, além de comentar sobre algumas aplicações de Redes Neurais na área de Sensoriamento Remoto.

O capítulo três apresenta a localização e a descrição da área de estudo selecionada. A origem, as características, as espécies, o uso, as pragas florestais e a

importância de espécies nativas, de *Eucalyptus* e de *Acácia*, existentes na região, são relatadas.

Por fim, os capítulos quatro, cinco, seis, sete e oito apresentam os materiais utilizados, a metodologia empregada, os resultados obtidos, uma discussão sobre estes resultados e as conclusões e sugestões para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

A seção 2.1 aborda o significado de classificar imagens e como isto é feito em imagens multi-espectrais, utilizando tanto uma classificação supervisionada quanto não-supervisionada. Além disto, esta seção realiza um breve comentário sobre alguns métodos de classificação, bastante difundidos, apresentando suas características, vantagens e desvantagens. As informações contidas nesta seção foram extraídas de EASTMAN (1996), LAPOLLI et al. (1993), CRÓSTA (1992), NOVO (1989), JENSEN (1986), RICHARDS (1986) e SWAIN & DAVIS (1978).

2.1 Classificação de imagens digitais

Antes de introduzir o conceito de classificação de imagens multi-espectrais é necessário saber o que são estas imagens e como elas são adquiridas.

As imagens multi-espectrais podem ser obtidas através de sensores a bordo de plataformas orbitais (satélites) ou sub-orbitais (aeronaves). Cada sensor da plataforma adquire uma imagem da superfície terrestre em uma determinada faixa do espectro-eletromagnético (em geral, esta faixa está entre a região do visível e a região de microondas). Desta forma, cada sensor produz, para uma mesma área varrida, uma imagem denominada banda.

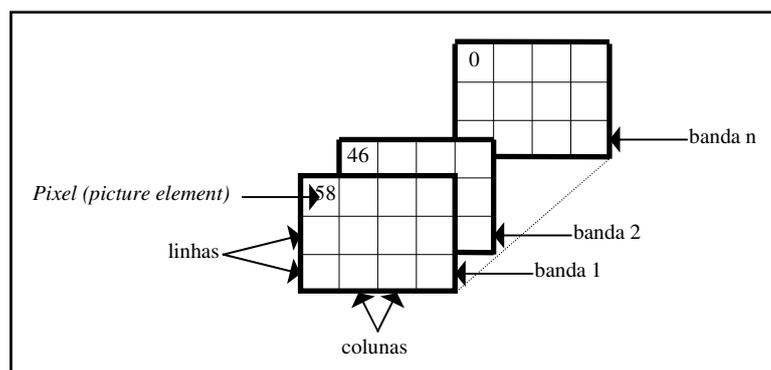


FIGURA 2.1 - Imagem multi-espectral. Adaptação: JENSEN (1986)

Conforme a Figura 2.1, é possível observar que uma banda é composta por um arranjo de elementos, denominados *pixels*, que estão dispostos em linhas e colunas. Estes *pixels* são caracterizados pela resolução e pelo atributo que possuem. A resolução diz respeito à área da superfície terrestre a qual o *pixel* representa. Por exemplo, para o

sensor TM, do satélite LANDSAT 5, a banda 1 possui uma resolução de 30 m x 30 m, de maneira que cada *pixel* desta banda representa 900 m² da superfície terrestre varrida¹. Já o atributo do *pixel*, também dito contador digital ou nível de cinza, refere-se a intensidade de energia eletromagnética (refletida ou emitida pela Terra), medida pelo sensor, para a área da superfície terrestre correspondente a resolução do *pixel*. O contador digital varia do preto (0) ao branco (255). A Figura 2.1 mostra o *pixel*² da linha 1 e coluna 1 com contador digital igual a 58 na banda 1 e 46 na banda 2.

Classificar imagens multi-espectrais³ significa atribuir cada *pixel* da imagem a uma determinada classe, em função de suas características espectrais. Entende-se como características espectrais, o valor que um determinado *pixel* recebe em cada uma das bandas do satélite que estão sendo utilizadas na classificação.

Existem dois tipos de classificação: a não-supervisionada e a supervisionada. Estas podem ser utilizadas como abordagens alternativas ou, mais freqüentemente, combinadas em metodologias híbridas.

A classificação não-supervisionada é indicada para quando não se tem conhecimento das possíveis classes existentes na imagem, pois, neste caso, o próprio algoritmo de classificação define as classes e atribui cada um dos *pixels* a uma delas. Assim, os *pixels*, cujas propriedades espectrais são semelhantes, formam grupos (ou *clusters*) no espaço multi-espectral. A Figura 2.2 ilustra o agrupamento dos *pixels* em uma *clusterização* que utiliza somente duas bandas (5 e 7).

Nota-se que, em geral, uma determinada classe possui subclasses devido a influências topográficas, umidade ou características físico-químicas do alvo em questão. No caso da vegetação, as subclasses podem surgir em função da diferença de umidade ou de biomassa (que difere conforme a idade das espécies vegetais), entre outras.

¹Maiores informações sobre os princípios básicos de Sensoriamento Remoto e sobre o sistema *LANDSAT* podem ser obtidas nos Anexos 02 e 03, respectivamente.

²Em imagens multi-espectrais cada *pixel* da imagem é visto como um vetor de *n* posições, onde *n* é o número de bandas que a compõem. Cada componente do vetor representa o contador digital de uma determinada banda.

³A classificação quando realizada com somente uma banda (um canal espectral) é dita unidimensional.

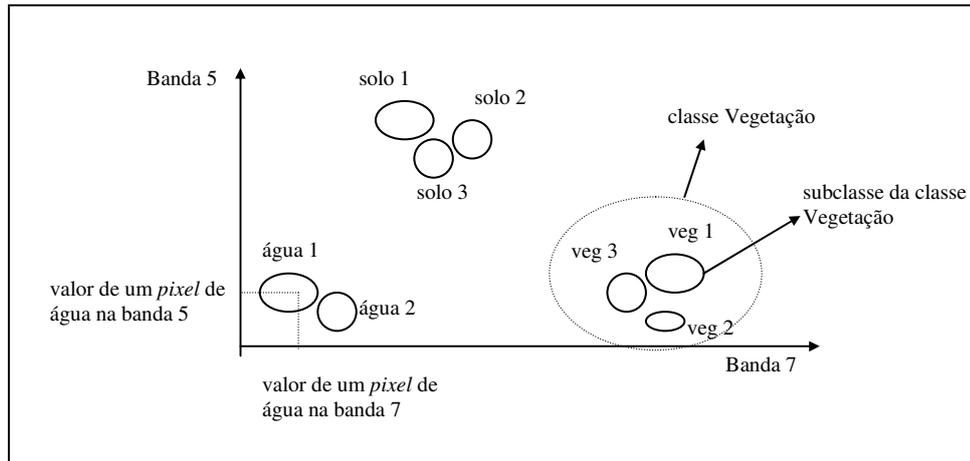


FIGURA 2.2 - Classes e subclasses no espaço bidimensional.
Adaptação: RICHARDS (1986)

O algoritmo básico do processo de *clusterização* pode ser resumido em três passos:

1. Obtenção arbitrária de um vetor de média associado a cada *cluster*;
2. Atribuição de cada *pixel* da imagem ao centro do *cluster* mais próximo conforme uma medida de distância (tipicamente, utiliza-se a distância Euclidiana⁴);
3. Cálculo do novo vetor de média (centro do *cluster*) em função dos *pixels* atribuídos a cada *cluster*.

Estes passos se repetem até que um determinado número de iterações seja efetuado ou até que se atinja certa minimização do erro médio quadrado entre os *pixels* atribuídos a cada *cluster* e o seu centro, ou seja, até que não haja mais mudança do centro de todos os *clusters*. Como, para isto, os centros dos *clusters* se movem, este processo é também denominado de Migração de Médias.

Entre os métodos de *clusterização* existentes, salienta-se: a *clusterização* pelo Pico do Histograma, a *clusterização* Hierárquica Aglomerativa e a *clusterização* por Passagem Simples. A Tabela I apresenta um breve comentário sobre estes métodos.

Após a formação dos *clusters* (processo de *clusterização*), estes podem ser identificados (rotulados) com o auxílio de mapas, fotografias aéreas e informações de visitas à região. Assim, é possível dizer que as classes são identificadas “a posteriori”.

⁴As fórmulas correspondentes às distâncias Euclidiana, Absoluta e de Mahalanobis podem ser vistas em JENSEN (1986) e RICHARDS (1986).

O ideal é utilizar este tipo de classificação para identificar as subclasses, antes de realizar uma classificação supervisionada.

Na classificação supervisionada as classes são definidas “a priori” e cada *pixel* da imagem é atribuído a uma determinada classe, conforme uma função discriminante preestabelecida⁵. Por sua vez, os parâmetros que descrevem esta função (tais como: média e matriz de covariância) são extraídos de um conjunto de amostras (denominado amostras de treinamento) que deve ser, também, previamente selecionado. Como a função discriminante depende dos parâmetros extraídos, o conjunto de amostras torna-se um fator decisivo para a obtenção de resultados satisfatórios na classificação. Desta forma, deve-se ter um cuidado especial durante a etapa de coleta de amostras: o conjunto de treinamento deve ser formado por uma quantidade suficiente de *pixels* representativos (conforme EASTMAN (1996), no mínimo dez vezes o número de bandas que estão sendo utilizadas na classificação) e homogêneos de cada uma das classes espectrais consideradas. Para auxiliar o processo de coleta de amostras, RICHARDS (1986) sugere o uso, sempre que possível, de mapas topográficos, fotografias aéreas da época de aquisição da imagem, idas a campo (verificação de campo) e do próprio conhecimento, da área de estudo, por um fotointérprete.

Entre os métodos de classificação supervisionados existentes, destacam-se: o método do Paralelepípedo, da Distância Mínima e de Máxima Verossimilhança Gaussiana. A Tabela II apresenta, resumidamente, as características, vantagens e desvantagens de cada um destes métodos. Recomenda-se SWAIN & DAVIS (1978), RICHARDS (1986) e JENSEN (1986) para a obtenção de maiores detalhes sobre os métodos de classificação aqui citados ou sobre outros métodos de classificação supervisionados, tais como: o Classificador de Mahalanobis e a Tabela *Look Up*.

Nas próximas seções, o método de *Clusterização* pelo Pico do Histograma e o método de Máxima Verossimilhança Gaussiana, utilizados neste trabalho, serão abordados mais detalhadamente.

⁵As classes podem ser vistas como distribuições de probabilidade, em geral, gaussianas. Neste caso, as subclasses apresentam distribuição de probabilidade unimodal, enquanto que as classes apresentam, freqüentemente, distribuição multimodal, por serem conjuntos de subclasses.

TABELA I - Métodos de *clusterização* (RICHARDS, 1986)

MÉTODO	CARACTERÍSTICAS	VANTAGENS	DESVANTAGENS
<i>Clusterização por Passagem Simples</i>	Amostras selecionadas aleatoriamente, da área a ser <i>clusterizada</i> , são dispostas em um <i>array</i> bidimensional. A primeira linha deste <i>array</i> é utilizada para obter os centros iniciais (a primeira amostra é o centro do primeiro <i>cluster</i>). Se a segunda amostra da primeira linha possuir uma distância maior da preestabelecida, entre ela e o primeiro <i>cluster</i> , então esta é usada para formar um novo <i>cluster</i> . Caso contrário, as duas amostras pertencerão ao mesmo <i>cluster</i> e a nova média obtida passa a ser o novo centro do <i>cluster</i> . Após o término da primeira linha do <i>array</i> , o desvio-padrão para cada <i>cluster</i> é calculado. Logo, cada amostra das linhas subseqüentes do <i>array</i> são verificadas e atribuídas ao <i>cluster</i> mais próximo, desde estejam dentro do desvio-padrão do <i>cluster</i> . Os <i>clusters</i> com um número de <i>pixels</i> menor do que o estipulado são considerados insignificantes e, conseqüentemente, são desconsiderados.	Redução de custo de <i>clusterização</i> , pois apenas parte da região a ser <i>clusterizada</i> é utilizada na determinação dos centros dos <i>clusters</i> . Não é necessário determinar de antemão o número de <i>clusters</i> a serem criados, pois o próprio algoritmo determina isto.	Em geral, ganha-se em velocidade, porém perde-se em acurácia. É necessário especificar tanto a distância mínima entre os centros dos <i>clusters</i> quanto o desvio-padrão para eles. O último conjunto de centros de <i>cluster</i> pode depender significativamente do caráter da primeira linha de amostras, visto que são elas que determinam os centros iniciais.
<i>Clusterização Hierárquica Aglomerativa</i>	Inicialmente, assume-se todos os <i>pixels</i> como sendo <i>clusters</i> individuais e, então, sistematicamente, fundem-se os <i>clusters</i> vizinhos em função da distância entre suas médias. O processo continua até que se atinja um grau de granularidade satisfatório. Em geral, utiliza-se a distância Euclidiana como medida de similaridade entre <i>clusters</i> .	Não é necessário especificar de antemão o número de <i>clusters</i> .	Geralmente, não encontra uma grande quantidade de aplicações em Sensoriamento Remoto, pois, para estas imagens, geralmente, um grande número de <i>pixels</i> está envolvido. Útil para a segmentação de imagens pequenas.
<i>Clusterização pelo Pico do Histograma</i>	Cria um histograma multidimensional com as bandas consideradas e, após, analisa-o na busca dos seus picos. Este método considera que as classes espectrais ou <i>clusters</i> estão localizados nos picos do histograma.	Também para este método, não é necessário especificar de antemão o número de <i>clusters</i> .	Algumas vezes, quando os dados são correlacionados pode ocorrer o surgimento de falsos picos. E, para agrupar os falsos picos a picos reais adjacentes é necessário um maior tempo computacional.

TABELA II - Métodos de classificação supervisionados (RICHARDS, 1986; JENSEN, 1986; CROSTA, 1992)

MÉTODO	CARACTERÍSTICAS	VANTAGENS	DESVANTAGENS
<i>Paralelepípedo</i>	Estabelece um quadrado ou paralelepípedo ao redor das amostras de treinamento de cada classe. O paralelepípedo é delimitado, sobre o histograma n-dimensional da imagem (sendo n o número de bandas consideradas), através do contador digital máximo e mínimo das amostras de treinamento. Assim, um determinado <i>pixel</i> X pertence a uma classe i, se, para todas as bandas, o valor de X se situa dentro do paralelepípedo correspondente a classe i.	Simplicidade e facilidade de implementação do método, além da rapidez computacional.	O paralelepípedo sempre abrange alguns <i>pixels</i> que não pertencem à classe, pois a correlação existente entre as bandas causa uma distribuição alongada dos <i>pixels</i> ao longo dos eixos. A intersecção entre paralelepípedos que representam classes diferentes provoca a atribuição de um único <i>pixel</i> a mais de uma classe. Raramente produz bons resultados.
<i>Distância Mínima</i>	A partir das amostras de treinamento, extrai o vetor de médias representante de cada classe. Após, cada <i>pixel</i> é atribuído à classe cujo vetor de médias apresenta a menor distância. Pode-se utilizar a distância Euclidiana, Absoluta ou de Mahalanobis entre o <i>pixel</i> e o vetor de médias.	Rapidez e facilidade de implementação.	Não considera a dispersão dos <i>pixels</i> em torno da média o que aumenta o erro de classificação.
<i>Máxima Verossimilhança Gaussiana</i>	Os <i>pixels</i> são atribuídos à classe cuja probabilidade de pertinência for maior. Isto é feito a partir de uma regra de decisão estabelecida a partir de parâmetros estatísticos (como a média e a matriz de covariância) obtidos das amostras de treinamento de cada classe.	Considera a dispersão em torno da média. Em geral, apresenta melhores resultados de classificação em relação aos métodos anteriores, se as amostras de treinamento são representativas e em quantidade suficiente.	Elevado tempo computacional se comparado com os métodos anteriores devido a necessidade de extração dos parâmetros estatísticos. Para uma maior precisão na classificação é necessário um número razoavelmente elevado de <i>pixels</i> de treinamento (mais de uma centena) para cada uma das classes.

2.2 Métodos tradicionais

2.2.1 Clusterização pelo Pico do Histograma

2.2.1.1 Características

Este método não-supervisionado é baseado na análise de um histograma multidimensional criado a partir das bandas consideradas na classificação. Assim, a questão principal é determinar os picos do histograma que serão, de fato, considerados como locais de classe. Define-se pico como sendo uma determinada posição no histograma, onde a frequência de *pixels* é maior do que nas posições vizinhas. Conforme EASTMAN (1996), existem duas abordagens para este método: a ampla e a fina.

Na abordagem ampla, as classes estão localizadas, somente, nos picos predominantes cuja frequência é maior do que todos os seus picos vizinhos não diagonais. Logo, as classes são separadas nos vales do histograma.

Contrariamente, pela abordagem fina, as classes estão presentes em cada um dos picos existentes, sendo estes predominantes ou não. Desta forma, um pico pode possuir picos vizinhos, não diagonais, com uma frequência superior de *pixels*. Neste caso, as classes são separadas tanto nos vales quanto nos picos.

A abordagem fina produz um número muito maior de *clusters* do que a abordagem ampla. Este número elevado se deve ao surgimento de um grande número de subclasses (em média, cerca de duas a três subclasses por classe espectral - EASTMAN, 1996).

2.2.1.2 Funcionamento

Este método de classificação não-supervisionado consiste de, praticamente, três passos (EASTMAN, 1996):

1. Obtenção do histograma multidimensional⁶. Este é formado pelas bandas que se deseja utilizar na *clusterização*. Nota-se que o histograma é discreto em função dos valores dos *pixels*, em cada banda, que são discretos (em geral, variam de 0 a 255);

⁶O *software* Idrisi limita para três o número de bandas utilizadas na aquisição do histograma. Neste caso, a escolha das bandas depende da aplicação (consultar seção 2.6.4).

2. Identificação dos picos do histograma conforme a abordagem escolhida;
3. Associação dos *pixels* da imagem ao pico mais próximo, para a produção de *clusters*.

A etapa final deste processo de *clusterização* está na interpretação dos *clusters* pelo analista (onde se dá a classificação não-supervisionada sobre o processo de *clusterização*). Nota-se que os *clusters* amplos são, em geral, fáceis de interpretar. Já os *clusters* finos exigem, muitas vezes, um esforço maior para serem identificados. Neste caso, o uso de mapas topográficos, fotografias aéreas e visitas ao terreno podem ser de grande auxílio. Salienta-se que neste processo pode ser necessário agrupar *clusters* para formar uma determinada classe (como exemplo: *clusters* que representam *Acácia mearsii* menor e maior do que três anos poderiam ser agrupados em uma mesma classe, caso esta diferenciação não fosse importante).

2.2.1.3 Considerações gerais

Conforme RICHARDS (1986), geralmente, os picos são comparados, apenas, com os seus vizinhos não diagonais. Entretanto, algoritmos mais sofisticados realizam, também, a comparação com os vizinhos diagonais. Isto evita o surgimento de falsos picos, mas aumenta consideravelmente o tempo computacional. A Figura 2.3 mostra qual o pico de um histograma que seria considerado como classe, tanto em uma avaliação não diagonal, quanto diagonal.

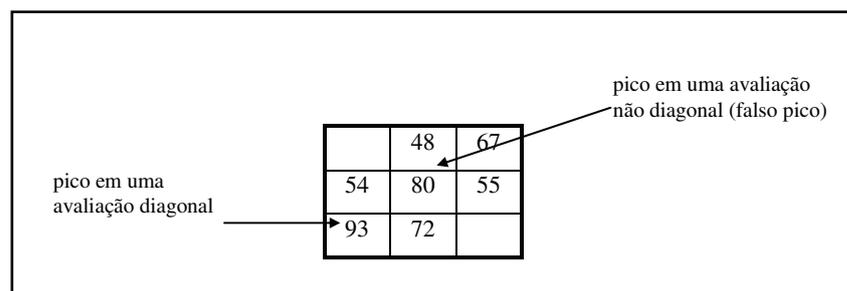


FIGURA 2.3 - Avaliação de picos em um histograma bidimensional.

Considera-se o pico com frequência igual a 80. Ao ser comparado com seus vizinhos não diagonais, ele seria considerado como pico predominante, onde estaria localizada uma classe. Entretanto, ele é um falso pico, pois ao ser comparado com os seus vizinhos diagonais, verifica-se a existência de um pico mais significativo (pico com frequência igual a 93). Assim, a classe deveria estar localizada no pico com frequência de 93 *pixels* e não no pico com frequência de 80.

Existem outros critérios, além deste, para a determinação dos picos. Alguns algoritmos determinam que as classes estão localizadas nos picos cujo tamanho ultrapassa um determinado limiar. Outros, aceitam como classe aqueles agrupamentos cujos picos têm cinco ou mais *pixels* do que as depressões vizinhas (RICHARDS, 1986).

2.2.2 Máxima Verossimilhança Gaussiana

Esta seção apresenta as características, o funcionamento e algumas considerações importantes sobre o método de Máxima Verossimilhança Gaussiana. As informações aqui contidas foram obtidas de NUNES (1995) e RICHARDS (1986).

2.2.2.1 Características

No método de Máxima Verossimilhança Gaussiana cada classe é descrita por uma distribuição de probabilidade normal. Esta distribuição descreve a chance de encontrar um *pixel*, de uma determinada classe, em uma certa posição do espaço multi-espectral.

Para tanto, é necessário extrair amostras representativas, de cada classe, para a obtenção dos parâmetros estatísticos⁷ da distribuição normal. Desta maneira, este método é considerado supervisionado.

Pode-se descrever o método de Máxima Verossimilhança Gaussiana em três etapas:

1. A seleção de amostras representativas e em quantidade suficiente, para cada tipo de cobertura (classe) pré-definida. Estas amostras formam o conjunto de treinamento que dever ser obtido, se possível, com o uso de informações de fotografias aéreas e/ou de mapas topográficos e/ou de dados de campo. É importante que as amostras

⁷ Algumas vezes, estes parâmetros são ditos assinaturas da classe.

sejam representativas, pois delas depende a obtenção dos parâmetros estatísticos. Além disto, um número de *pixels*/classe maior ou igual a dez vezes o número de bandas utilizadas na classificação é considerado suficiente;

2. A extração dos parâmetros estatísticos (média e matriz de covariância) para cada classe. Estes parâmetros permitirão a criação de uma regra de decisão, que decide a qual classe pertencerá cada *pixel* da imagem.
3. A classificação de toda a imagem, onde é calculada a probabilidade de cada *pixel* pertencer a cada classe. Os *pixels* são atribuídos à classe cuja probabilidade de pertinência é maior.

2.2.2.2 Funcionamento

Sendo X um vetor de componentes, cujos valores são os níveis de cinza de um *pixel*, em cada uma das bandas consideradas e, W_i como sendo a classe i, uma das “n” possíveis classes pré-definidas; como classificar um *pixel* X em uma classe W_i ?

No método de Máxima Verossimilhança, um *pixel* X pertence a uma determinada classe W_i se:

$$P(W_i/X) > P(W_j/X), \forall j \neq i \quad [2.1]$$

Nota-se que $P(W_i/X)$ é a probabilidade de X pertencer a classe W_i , ou pode-se dizer que é a verossimilhança de X em relação à classe W_i . É dita probabilidade “a posteriori”, pois é obtida como resultado da classificação.

Desta forma, a questão principal é determinar a $P(W_i/X)$, sendo $i=1..n$. Para tanto, tem-se o Teorema de Bayes que afirma:

$$P(W_i/X) = \frac{P(X/W_i) \cdot P(W_i)}{P(X)} \quad [2.2]$$

$P(W_i)$ é a probabilidade de ocorrência da classe i, ou de outra forma, é a porcentagem de *pixels* da imagem que pertencem a W_i . É a probabilidade considerada “a priori”, pois é obtida pelos conhecimentos que o especialista tem sobre a região,

antes da classificação. $P(X)$ é a probabilidade de encontrar um *pixel* de qualquer classe na posição X . Quanto maior for $P(X)$, menor é a chance de X pertencer a uma classe específica. $P(X)$ é obtida por:

$$P(X) = \sum_{i=1}^n P(X/W_i) \cdot P(W_i) \quad [2.3]$$

$P(X/W_i)$ é a distribuição de probabilidade de X dado uma classe W_i , ou seja, é a probabilidade interna da classe i . Pode-se dizer, também, que é a probabilidade de encontrar um *pixel* da classe W_i na posição X . Esta probabilidade é obtida através de amostras das diversas classes.

Substituindo $P(W_i/X)$ da relação [2.1], conforme o Teorema de Bayes [2.2], tem-se:

$$X \in W_i, \text{ se } \frac{P(X/W_i) \cdot P(W_i)}{P(X)} > \frac{P(X/W_j) \cdot P(W_j)}{P(X)}, \quad \forall j \neq i \quad [2.4]$$

Sendo $P(X)$ um termo comum, este pode ser eliminado de [2.4]. Assim:

$$X \in W_i, \text{ se } P(X/W_i) \cdot P(W_i) > P(X/W_j) \cdot P(W_j), \quad \forall j \neq i \quad [2.5]$$

Muitas vezes, a probabilidade “a priori” é desconhecida. Neste caso, assume-se que as probabilidades de ocorrência das “n” classes são iguais. Isto simplifica a relação obtida em [2.5], que passa a ser:

$$X \in W_i, \text{ se } P(X/W_i) > P(X/W_j), \quad \forall j \neq i \quad [2.6]$$

Para o método de Máxima Verossimilhança Gaussiana, assume-se que as amostras possuem distribuição normal de probabilidade nas diversas classes. Logo, $P(X/W_i)$ é dada por⁸ :

$$P(X/W_i) = (2\pi)^{-N/2} |\Sigma_i|^{-1/2} \exp\{ -1/2 (X-\mu_i)^T \Sigma_i^{-1} (X-\mu_i) \} \quad [2.7]$$

⁸ Este é um modelo normal multivariado, pois está expandido para M bandas.

Onde N é o número de bandas (que corresponde ao número de componentes de X); Σ_i é a matriz de covariância da classe i , para as N bandas e μ_i é o vetor que contém o valor médio de nível de cinza da classe i , para cada banda⁹.

A matriz de covariância¹⁰ é obtida da seguinte forma:

$$\Sigma_i = (1/k-1) \sum_{j=1}^k (X_j - \mu_i) (X_j - \mu_i)^T \quad [2.8]$$

E, o vetor médio é dado por:

$$\mu_i = (1/k) \sum_{j=1}^k X_j \quad [2.9]$$

Sendo k , o número de *pixels*, do conjunto de treinamento, representantes da classe i .

Ao aplicar o logaritmo natural à equação [2.7], obtém-se:

$$\ln P(X/W_i) = -N/2 \ln (2\pi) - 1/2 \ln |\Sigma_i| - 1/2 (X - \mu_i)^T \Sigma_i^{-1} (X - \mu_i) \quad [2.10]$$

Como os termos $-N/2$, $\ln (2\pi)$ e $1/2$ são comuns para todas as classes, aumentando o tempo computacional, estes são desconsiderados. Assim, após estas simplificações matemáticas, obtém-se a seguinte função de discriminação:

$$G_i(X) = -\ln |\Sigma_i| - (X - \mu_i)^T \Sigma_i^{-1} (X - \mu_i) \quad [2.11]$$

Logo:

$$X \in W_i, \text{ se } G_i(X) > G_j(X), \forall j \neq i \quad [2.12]$$

sendo esta a Regra de Decisão utilizada na classificação por Máxima Verossimilhança Gaussiana.

⁹ T significa matriz transposta e -1 é a matriz inversa.

¹⁰ Esta matriz é simétrica e reflete o grau de correlação, entre as bandas, para uma determinada classe i . A diagonal principal mostra a variância da classe i em cada banda.

2.2.2.3 Considerações gerais

Para o método de Máxima Verossimilhança Gaussiana, a obtenção de bons resultados na classificação depende, fundamentalmente, do conjunto de treinamento escolhido. A escolha de um conjunto homogêneo de *pixels* representativos produz uma curva normal bem delineada. Conseqüentemente, uma curva fortemente bimodal sugere a existência de tipos de coberturas diferentes em uma mesma classe. Da mesma forma, a existência de valores extremos, que parecem não pertencer à curva principal, indicam uma não homogeneidade dos *pixels* escolhidos para a classe.

Uma outra consideração a fazer é em relação ao uso de *thresholds* (limites) para evitar a produção de uma classificação ruim. Os *thresholds* podem ser vistos como cortes na curva de distribuição normal. Desta maneira, eles delimitam a porcentagem de *pixels* que serão classificados e os que serão rejeitados (Figura 2.4). Os *pixels* rejeitados são atribuídos a uma classe denominada desconhecida.

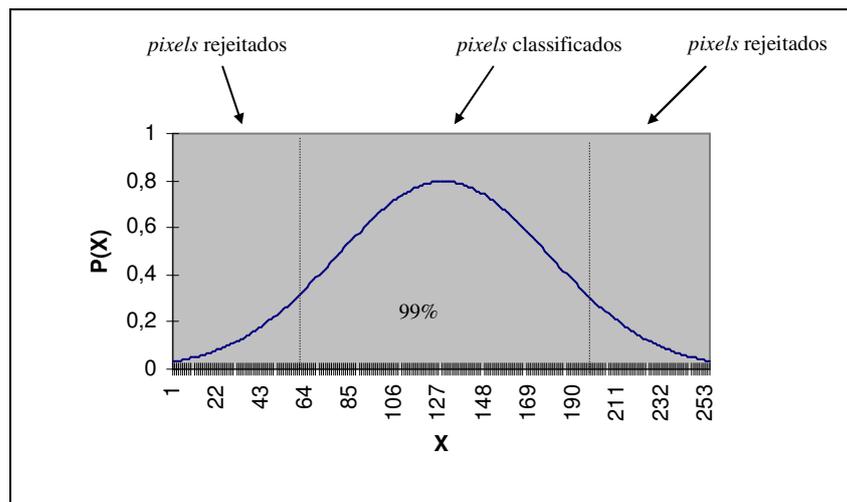


FIGURA 2.4 - Uso de *threshold*

Rejeita-se os *pixels* cuja probabilidade de pertencer a qualquer uma das classes seja muito pequena (em geral, menor ou igual a 1%).

No método de Máxima Verossimilhança Gaussiana, o *threshold* (T_i) é aplicado juntamente às funções discriminantes, da seguinte forma:

$$\begin{array}{l} X \in W_i, \text{ se } G_i(X) > G_j(X), \forall j \neq i \\ \text{e} \\ \text{se } G_i(X) > T_i \end{array} \quad [2.13]$$

Assim, um *pixel* pertence a classe i se a probabilidade de pertencer a esta classe é maior do que a todas as outras e, se esta probabilidade é maior do que o limite estabelecido.

Enfim, o *threshold* é interessante no momento em que podem existir outras classes, na imagem, que não foram consideradas no conjunto de treinamento. Além disto, ele pode ser útil no caso de classes que se sobrepõem. Desta forma, os *pixels* situados em posições críticas (sobreposição de classes) ou que não pertençam a nenhuma das classes preestabelecidas são rejeitados (classificados como desconhecidos).

A próxima seção aborda a classificação de imagens multi-espectrais através de dois modelos de Redes Neurais: os Mapas de *Kohonen* e as Redes Neurais Multinível com *BackPropagation*.

2.3 Redes Neurais Artificiais

Uma Rede Neural é um conjunto de elementos processadores individuais (neurônios) com várias entradas e uma única saída, interconectados através de pesos sinápticos e agrupados sob as mais diversas topologias (Figuras 2.7 e 2.14). Cada neurônio recebe nas suas entradas valores das saídas dos neurônios conectados a ele. Estes sinais de entrada (X) são multiplicados pelos respectivos pesos sinápticos das conexões (W) e somados, gerando o valor de ativação do neurônio (Figura 2.5). O valor de saída do neurônio é aproximadamente binário, resultado da comparação entre o seu valor de ativação e um determinado valor de limiar (*threshold*).

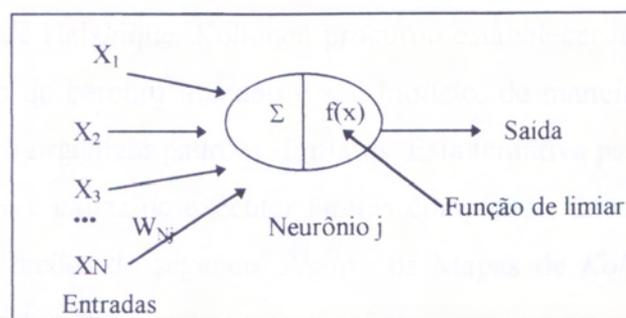


FIGURA 2.5 - Neurônio. Adaptação: FREEMAN & SKAPURA (1991)

Uma Rede Neural possui um conjunto de neurônios de entrada que recebe o vetor de sinais externos a ser processado. Estes sinais são propagados pelas interconexões da rede, ativando sucessivamente todos os neurônios. A rede possui, também, um conjunto de neurônios de saída, cujos valores representam o vetor de saída ou resposta da rede.

A rede tem a capacidade de aprender por indução, a partir de um conjunto de treinamento. Durante o treinamento, os pesos sinápticos são ajustados de acordo com procedimentos matemáticos específicos, tais como: otimização discreta, minimização de erros, *clusterização* de vetores, entre outros, que determinam como será realizado o treinamento, ou aprendizado, da Rede Neural. No final deste processo, o conhecimento adquirido do conjunto de treinamento será representado pelo conjunto de pesos da rede.

Por fim, uma característica muito importante de uma Rede Neural é a capacidade de generalização do conhecimento adquirido, de maneira que ela possa responder adequadamente a padrões de entrada com os quais não foi treinada.

Os tópicos que seguem explanam sobre a estrutura e o funcionamento de dois tipos de Redes Neurais Artificiais (RNA's), muito utilizadas na classificação de imagens digitais. São elas: os Mapas Auto-Organizáveis de *Kohonen* e as Redes Neurais Multinível com *BackPropagation*. Para tanto, as seguintes referências foram consultadas: NUNES (1995), FREEMAN (1991), KOHONEN (1989) e BALANIUK (1989).

2.3.1 Mapas de *Kohonen*

2.3.1.1 Características do modelo

Este modelo de RNA foi criado em 1981, pelo engenheiro Teuvo Kohonen, da Universidade de Helsinque. Kohonen procurou estabelecer uma relação direta entre o comportamento do cérebro humano e seu modelo, de maneira que este pudesse ser utilizado para auto-organizar padrões similares. Esta tentativa partiu do princípio de que o cérebro humano é capaz de executar tarefas complexas, tal como o reconhecimento de padrões, em frações de segundo. Assim, os Mapas de *Kohonen* são baseados na forma como o cérebro armazena as informações.

Sabe-se que os neurônios que executam atividades similares estão localizados próximos uns dos outros. Conseqüentemente, o cérebro é dividido em grupos (regiões) de neurônios, cada qual respondendo a estímulos específicos. Desta forma, encontram-se regiões responsáveis pela visão, audição, olfato e fala, entre outras.

Os neurônios estão altamente interconectados lateralmente. Desta maneira, a estimulação de um neurônio provoca uma reação em seus vizinhos físicos. A Figura 2.6 ilustra a reação ocorrida ao redor de um neurônio estimulado (ao centro, em preto). Alguns neurônios vizinhos são estimulados (em vermelho) e outros inibidos (em azul). Nota-se que a intensidade do estímulo (sinais nervosos recebidos) diminui conforme os neurônios se distanciam do centro de ativação.

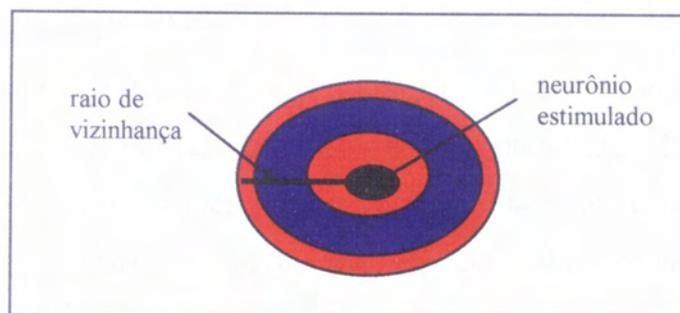


FIGURA 2.6 - Processo de estimulação de neurônios do cérebro.
Adaptação: NUNES (1995)

Nos Mapas de *Kohonen*, os padrões são repassados à rede para serem agrupados em regiões (*clusters*), conforme a similaridade. Assim, um ou mais neurônios vizinhos formam as classes espectrais (como: solo exposto, água, vegetação, corpos d'água, pastagem, área urbana). Pode-se dizer, também, que os Mapas de *Kohonen* reduzem o espaço de entrada multidimensional para um espaço bidimensional.

Este modelo é não-supervisionado, apresenta uma topologia tipicamente bidimensional (mapa), possui duas camadas (entrada e intermediária) e seu aprendizado é competitivo (Figura 2.7).

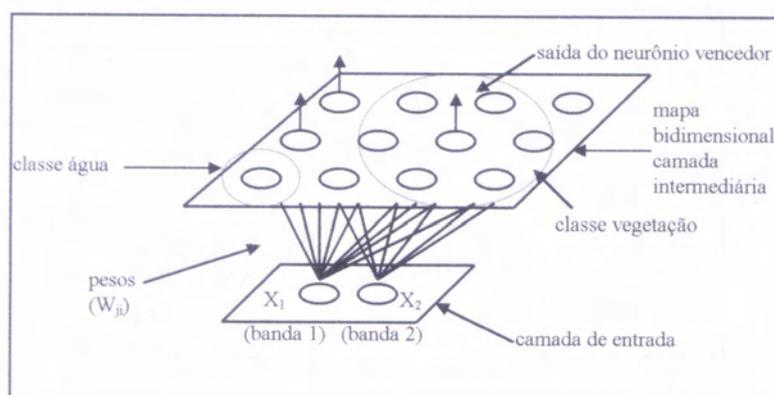


FIGURA 2.7 - Exemplo de topologia de uma rede de *Kohonen*
Adaptação: NUNES (1995)

Nota-se que a camada de entrada é totalmente interconectada com a camada intermediária (mapa bidimensional), através de pesos de conexão. Por sua vez, a camada intermediária é formada por uma malha de neurônios que se auto-organizam para aprender os padrões de entrada.

O aprendizado competitivo consiste em determinar o neurônio do mapa que apresenta o maior valor de saída, para uma determinada entrada. Este neurônio é dito neurônio vencedor. Assim, durante o processo de aprendizado da rede, os neurônios competem entre si até que sejam definidos os neurônios que melhor representam cada classe. Para tanto, a cada iteração, apresenta-se um padrão de entrada (X_p) à rede e identifica-se o neurônio vencedor. Em seguida, os pesos associados a este neurônio e aos seus vizinhos, que pertencem ao raio de vizinhança, são ajustados. Entende-se por raio de vizinhança, a distância entre o neurônio vencedor e os demais neurônios da rede. Este é estabelecido no início de todo o processo, devendo cobrir cerca da metade da dimensão do mapa (exemplo: para um mapa bidimensional de 3 x 3 neurônios, sugere-se um raio de vizinhança a cerca de 1.5 - NUNES, 1995).

Como, nas RNA's, o conhecimento está armazenado nos pesos da rede (que biologicamente equivalem aos processos sinápticos¹¹), o objetivo é orientar os pesos para as entradas¹². Assim, o neurônio vencedor é aquele cujo vetor de pesos é o mais próximo do vetor de entrada. Conseqüentemente, este neurônio é o que produz a maior saída. Na Figura 2.8, observa-se que o neurônio vencedor é o de número 2, pois este apresenta um vetor de pesos (W_{p2}) mais próximo do padrão X_p fornecido à rede.

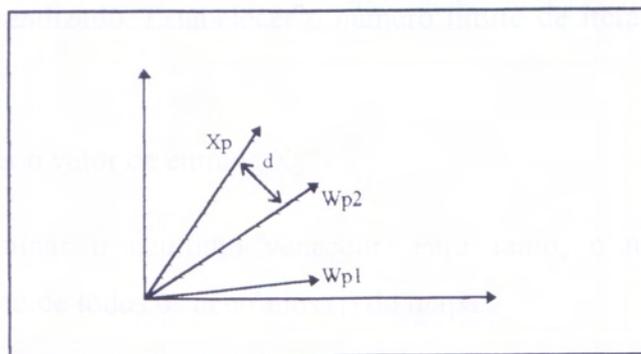


FIGURA 2.8 - Pesos e entradas em um espaço bidimensional
Adaptação: NUNES (1995)

Em imagens multi-espectrais, os padrões de entrada são vetores cujos componentes são os níveis de cinza de um *pixel*, em cada uma das bandas consideradas (Figura 2.7).

¹¹ Os neurônios se ligam através de pontos de contato, denominados sinapses. Estes, por sua vez, permitem a propagação de impulsos elétricos por todo o sistema nervoso. Estima-se a existência de 10^{14} a 10^{15} sinapses, com 10.000 sinapses, por neurônio, em média (BALANIUK, 1989).

¹² O vetor de pesos e o vetor de entradas possuem a mesma dimensão.

Devido ao elevado tempo computacional necessário na determinação dos *clusters*, é comum utilizar parte da imagem para a etapa de aprendizado. Desta forma, *pixels* aleatórios são escolhidos e fornecidos à rede, para fins de ajuste dos pesos.

Na etapa de reconhecimento, cada um dos *pixels* da imagem é considerado como padrão de entrada. A rede, por sua vez, informará o *cluster* ao qual o *pixel* pertence, ativando um ou mais neurônios do mapa. É necessário treinar a rede exaustivamente para que haja sucesso na fase de reconhecimento, resultante de *clusters* bem formados.

2.3.1.2 Funcionamento

Considerando X_p como um vetor de entrada que representa o padrão p ; W_{ji} como o peso de conexão entre a entrada i e o neurônio j do mapa; Y_{pj} como sendo a saída do neurônio j para o padrão p ; pode-se descrever o processo de aprendizado, deste modelo, nos seguintes passos:

1. Inicializar os pesos da rede (com valores pequenos e aleatórios, ± 0.5), o raio da vizinhança (cerca da metade da dimensão do mapa) e o coeficiente de aprendizado. Estabelecer o número limite de iterações para o processo (t_{max}).
2. Aplicar o vetor de entrada X_p .
3. Determinar o neurônio vencedor. Para tanto, é necessário calcular a ativação de todos os neurônios (j) do mapa:

$$Y_j = \sum_{i=1}^N X_{pi} \cdot W_{ji} \quad [2.14]$$

onde N é o número de componentes do vetor de entrada. O neurônio vencedor é aquele que possui a maior ativação.

Atualizar os pesos do neurônio vencedor e dos neurônios vizinhos que pertencem ao raio de vizinhança preestabelecido. Logo:

$$W_{ji}(t+1) = \begin{cases} W_{ji}(t) + \alpha(t) (X_{pi}(t) - W_{ji}(t)), & \text{se } j \in \text{a vizinhança} \\ W_{ji}(t), & \text{se } j \notin \text{a vizinhança} \end{cases} \quad [2.15]$$

$(X_{pi}(t) - W_{ji}(t))$ é a distância (d), em geral Euclidiana, entre a entrada i do padrão p e o peso do neurônio (j) correspondente. Assim:

$$(X_{pi}(t) - W_{ji}(t)) = d_{pj} = \left\{ \sum_{i=1}^N (X_{pi} - W_{ji})^2 \right\}^{1/2} \quad [2.16]$$

$\alpha(t)$ é o coeficiente de aprendizado que representa uma fração da distância entre a entrada atual e o peso. É obtido da seguinte forma:

$$\alpha(t) = \alpha_0 (\alpha_f / \alpha_0)^{t/t_{\max}} \quad [2.17]$$

Nota-se que α_0 (coeficiente de aprendizado inicial) e α_f (coeficiente de aprendizado final) devem ser definidos no início do treinamento (passo 1). Além disto, t é a iteração atual e t_{\max} é o número máximo de iterações preestabelecidas.

Este coeficiente ($\alpha(t)$) tende a diminuir a cada iteração, de modo que, inicialmente, grandes correções são aplicadas ao vetor de pesos e, ajustes finos, são realizados no final do treinamento. A Figura 2.9 ilustra a função que descreve o coeficiente de aprendizado no tempo.

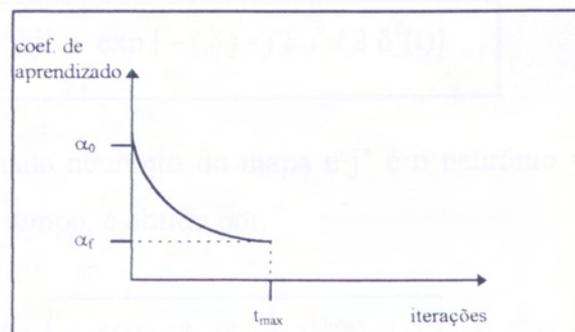


FIGURA 2.9 - Comportamento do coeficiente de aprendizado

Adaptação: NUNES (1995)

Uma vizinhança discreta ou contínua necessita ser estabelecida para que se definam quais os neurônios que precisam receber o ajuste de pesos.

Na vizinhança discreta, mede-se a distância em unidades, definindo-se, desta forma, o parâmetro de vizinhança $\delta(t)$. Assim, conforme o exemplo mostrado na Figura 2.10, o neurônio 5 está a uma distância de duas unidades do neurônio vencedor (13), ou seja, $\delta(0)=2$.

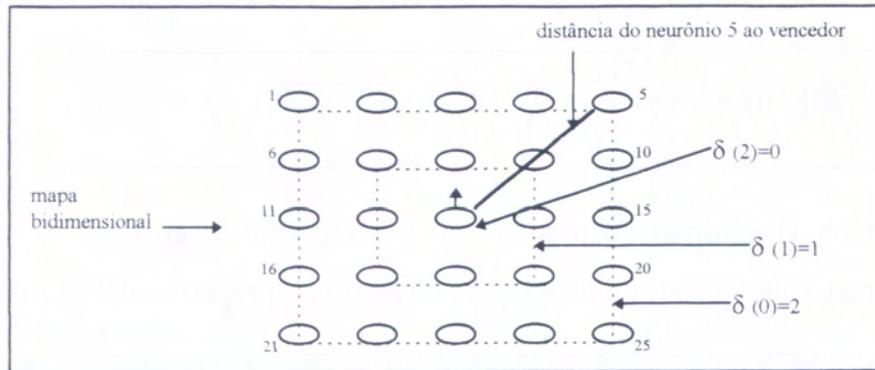


FIGURA 2.10 - Exemplo de determinação da vizinhança discreta em torno do neurônio vencedor 13. Adaptação: KOHONEN (1989)

Nota-se que, neste exemplo, a vizinhança diminui de uma unidade, a cada iteração. Para o mapa da Figura 2.10, três iterações são suficientes para reduzir a vizinhança a zero, de modo que somente o neurônio vencedor seria atualizado.

Na abordagem contínua, é possível visualizar a vizinhança como uma distribuição gaussiana sobre o mapa, onde o neurônio vencedor estaria no ponto médio de cada curva¹³. Neste caso, a vizinhança $h_{jj'}$ é dada por:

$$h_{jj'} = \exp \left[- \frac{(\|j - j'\|)^2}{2 \delta^2(t)} \right] \quad [2.18]$$

onde j é um determinado neurônio do mapa e j' é o neurônio vencedor. E, $\delta(t)$, que reduz a vizinhança no tempo, é obtido por:

$$\delta(t) = \delta_0 \left(\frac{\delta_f}{\delta_0} \right)^{t/t_{\max}} \quad [2.19]$$

¹³ Biologicamente, isto se refere a reação que ocorre ao redor de um neurônio estimulado, onde o neurônio central recebe o estímulo máximo.

Aqui, também é necessário definir δ_0 (coeficiente de aprendizado inicial para vizinhança contínua) e δ_f (coeficiente de aprendizado final para vizinhança contínua) no início do treinamento (passo 1).

$(\|j - j'\|)^2$ é a distância Euclidiana entre as posições físicas dos neurônios no mapa. Entende-se por posições físicas, os índices de linha e coluna em uma mapa bidimensional. Conforme a Figura 2.10, o neurônio 5 está na linha 1 (j_l) e na coluna 5 (j_c). Logo:

$$\boxed{(\|j - j'\|)^2 = (\sqrt{(j_c - j'_c)^2 + (j_l - j'_l)^2})^2 = (j_c - j'_c)^2 + (j_l - j'_l)^2} \quad [2.20]$$

No caso da vizinhança contínua, o teste de pertinência do neurônio na vizinhança fica incluso na própria forma de atualização dos pesos, que passa a ser:

$$\boxed{W_{ji}(t+1) = W_{ji}(t) + \alpha(t) h_{jj'} (X_{p_i}(t) - W_{ji}(t)), \text{ para } \forall j} \quad [2.21]$$

Com este ajuste de pesos, os neurônios atualizados são orientados (aproximados) para o padrão X_p .

5. Repetir a partir do passo 2.

O processo encerra após um número determinado de iterações.

2.3.1.3 Considerações gerais

O número de neurônios, necessário para se constituir o mapa, depende da complexidade do conjunto de dados de entrada e do grau de agrupamento (granulosidade) desejado. Em geral, para imagens multi-espectrais, a complexidade aumenta proporcionalmente ao número de bandas que estão sendo utilizadas ou, em outras palavras, ao número de componentes do vetor de entrada. Em princípio, considera-se cada classe como sendo representada por, somente, um neurônio. Entretanto, subestimar o número de neurônios pode prejudicar a capacidade de generalização do mapa, na etapa de reconhecimento, produzindo resultados ruins de *clusterização*. Além disto, é possível utilizar um mapa tridimensional ao invés de um bidimensional. NUNES (1995) utiliza um mapa tridimensional (cubo) e atribui a cada

eixo as componentes RGB. Desta forma, ele associa cores às classes, de modo que classes similares assumem cores próximas.

Já o número de iterações é estabelecido conforme a acurácia desejada e o tempo computacional disponível.

Outra questão a ser considerada é em relação ao cálculo da distância (passo 4). Em geral, utiliza-se a Distância Euclidiana para determinar a distância entre o vetor de peso e o vetor de entrada. Porém, é possível a utilização da Distância Absoluta entre Pontos ou a Distância de Mahalanobis¹⁴, entre outras.

Convém salientar que para a Rede de *Kohonen*, as entradas necessitam ser normalizadas para o mesmo espaço dos pesos. Isto garante que ambos os vetores, de entrada e de peso, tenham o mesmo tamanho, podendo ser comparados e aproximados corretamente.

Por fim, este modelo permite visualizar graficamente o estado da rede e as relações de vizinhança entre os neurônios, a cada iteração. Suponha uma rede de 3 x 3 neurônios e com vetores de entrada compostos por dois componentes (X_1 e X_2 - Figura 2.11). A Figura 2.12 ilustra a forma gráfica desta rede não treinada (rede hipotética), no espaço correspondente aos vetores de pesos (bidimensional, neste caso: $W_1 \times W_2$). Nesta Figura, as linhas estabelecem as vizinhanças físicas entre os neurônios (como exemplo: para o mapa da Figura 2.11, o neurônio cinco é vizinho de todos, logo ele se encontra ligado a todos os demais) e os pontos são os vetores de peso de cada um dos neurônios do mapa. Nota-se que no início do processo os pesos ocupam posições aleatórias no espaço bidimensional (Figura 2.12).

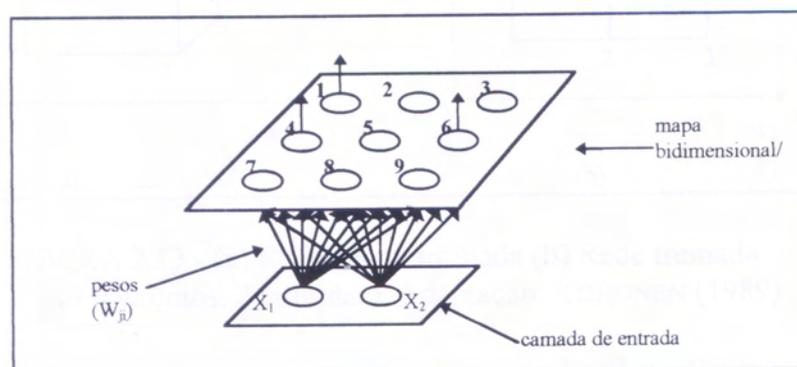


FIGURA 2.11 - Rede hipotética (9 neurônios, 2 entradas). Adaptação: NUNES (1995)

¹⁴ Maiores informações sobre a Distância Absoluta entre pontos ou a Distância de Mahalanobis podem ser obtidas em Jensen(1986).

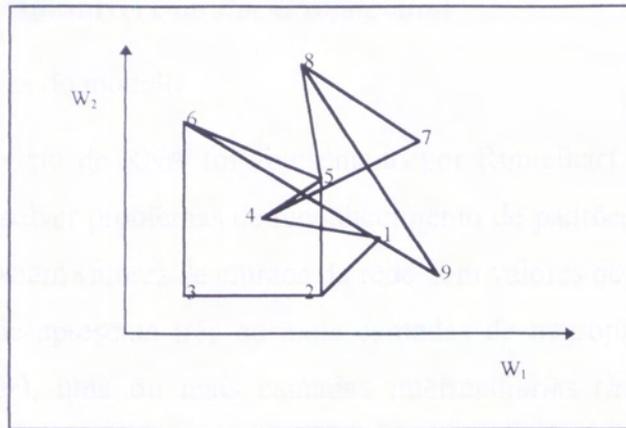


FIGURA 2.12 - Rede não treinada (9 neurônios, 2 entradas) com pesos inicializados com valores aleatórios

A Figura 2.13a ilustra a mesma rede sendo treinada, enquanto que a Figura 2.13b mostra o estado dos pesos após o término do treinamento. Nota-se que, durante o processo de treinamento, os vetores de pesos dos neurônios são ajustados de maneira a se alinharem com os vetores de treinamento. Assim, a vantagem deste processo é a possibilidade de visualizar o treinamento da rede passo a passo. Porém, a única limitação está no fato de que a forma gráfica é possível, somente, para um vetor de entrada com até três componentes¹⁵.

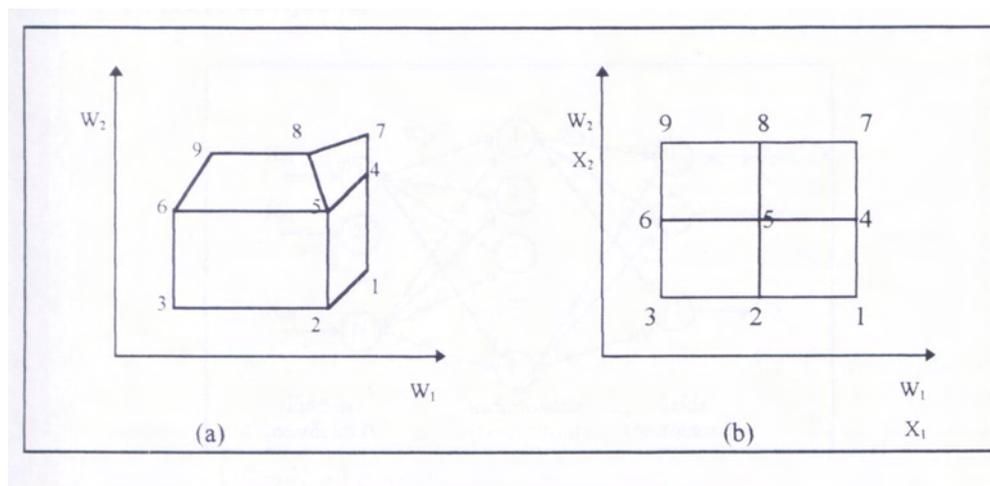


FIGURA 2.13 - (a) Rede sendo treinada (b) Rede treinada (9 neurônios, 2 entradas). Adaptação: KOHONEN (1989)

¹⁵ Este processo também é denominado de Auto-Organização da rede. Muitas vezes, os vetores de peso adquirem uma distribuição uniforme sobre uma área triangular ou retangular. Maiores informações sobre este processo podem ser encontradas em KOHONEN (1989).

2.3.2 Rede Neural Multinível com *BackPropagation*

2.3.2.1 Características do modelo

Este modelo de RNA foi apresentado por Rumelhart et al. (1986). É um modelo capaz de resolver problemas de reconhecimento de padrões complexos, através de funções que mapeiam valores de entrada da rede com valores de saída desejados.

Esta rede apresenta três ou mais camadas de neurônios: uma camada de entrada (*input layer*), uma ou mais camadas intermediárias (*hidden layer*) e uma camada de saída (*output layer*). A sua topologia é totalmente interconectada para frente (*feedforward*), não existindo conexões retro-alimentadas, e onde nenhuma conexão passa diretamente por sobre uma outra mais a frente (Figura 2.14).

O número de neurônios das camadas de entrada e de saída é definido de acordo com o problema ao qual a rede tentará solucionar. Entretanto, não existe uma regra que defina o número de neurônios intermediários, ou até mesmo o número de camadas intermediárias, de maneira que isto deve ser definido de forma intuitiva. Inicialmente, se o número de neurônios definido for muito alto, isto pode fazer com que apenas alguns neurônios especializem-se em características úteis. Porém, se o contrário ocorrer e o número de neurônios for insuficiente, pode acontecer da rede não conseguir aprender os padrões desejados.

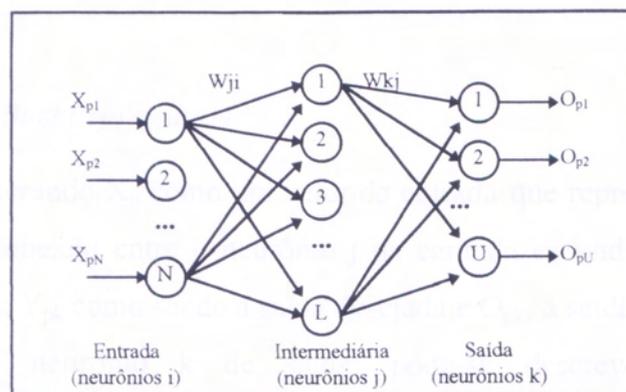


FIGURA 2.14 - Topologia de uma RNA Multinível com *BackPropagation*
Adaptação: FREEMAN & SKAPURA (1991)

Outra característica deste modelo é o aprendizado supervisionado baseado em duas fases: propagação e adaptação.

O treinamento ou aprendizado supervisionado (*supervised-learning*) consiste em fornecer à rede um conjunto de estímulos (padrões de entrada) e a saída

desejada correspondente. Inicialmente, o primeiro padrão de entrada é propagado até a saída (fase de propagação). Após, na fase de adaptação, um sinal de erro na saída é computado e transmitido de volta para cada neurônio da camada intermediária que contribuiu para a saída obtida. Desta forma, cada neurônio da camada intermediária recebe somente uma parte do erro total, conforme a contribuição relativa que o neurônio teve na saída gerada. Este processo repete-se, camada por camada, até que cada neurônio da rede receba o seu erro correspondente. Daí o nome *BackPropagation*, pois o aprendizado baseia-se na propagação retrógrada do erro para níveis superiores da rede.

Em seguida, os pesos existentes nas conexões entre os neurônios são atualizados de acordo com o erro recebido pelo neurônio associado.

Esta regra de aprendizado é uma generalização da Regra LMS (*Least Mean Square Error*), também conhecida como Regra Delta.

O processo de aprendizado, com as devidas alterações de pesos, permanece até o momento em que a saída obtida pela Rede Neural, para cada um dos padrões de entrada, seja próxima o bastante da saída desejada, de forma que a diferença entre ambas seja aceitável. Esta diferença é obtida através do cálculo do Erro Médio Quadrado (Fórmula 2.38). Considera-se diferença aceitável aquela que for menor ou igual a um erro previamente estipulado, em geral 1% ou 0.5%.

2.3.2.2 Algoritmo *BackPropagation*

Considerando X_p como um vetor de entrada que representa o padrão p ; W_{ji} como o peso de conexão entre o neurônio j da camada escondida e o neurônio i da camada de entrada; Y_{pk} como sendo a saída desejada e O_{pk} , a saída obtida pela rede para o padrão p do neurônio k de saída; pode-se descrever o algoritmo de *BackPropagation*¹⁶ nos seguintes passos:

1. Inicializar os pesos e os parâmetros da rede (coeficiente de aprendizado, parâmetro do momento¹⁷).
2. Aplicar o vetor de entrada X_p à Rede Neural.

¹⁶ Nota-se que este algoritmo inclui as fases de propagação e de adaptação da Rede Neural. A fase de adaptação começa a partir do passo 7. Maiores informações sobre as deduções matemáticas das fórmulas aqui descritas podem ser obtidas em FREEMAN (1991).

¹⁷ Estes parâmetros são discutidos em 2.3.2.3.

3. Calcular os valores internos (ativação) dos neurônios (j) da camada escondida (h):

$$\text{net}_{pj}^h = \sum_{i=1}^N W_{ji}^h \cdot X_{pi} + \theta_j^h \quad [2.22]$$

sendo N o número de neurônios da camada de entrada e θ_j um valor de limiar do neurônio j. θ_j , conhecido por *bias*, tem a função de contribuir na convergência da rede. Na verdade, ele funciona como um peso a mais a ser adicionado ao somatório acima descrito ou, em outras palavras, o *bias* é um neurônio com entrada constante em “1”. Cada neurônio da camada intermediária e da camada de saída possui o seu próprio *bias* (Figura 2.17).

4. Calcular as saídas dos neurônios da camada escondida:

$$i_{pj}^h = f(\text{net}_{pj}^h) \quad [2.23]$$

sendo f a aplicação de uma função de ativação. Em geral, utiliza-se a função sigmoideal (Figura 2.15) ou a função tangente hiperbólica (Figura 2.16).

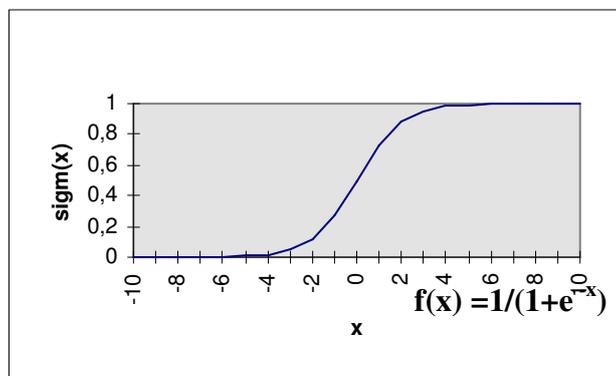


FIGURA 2.15 - Função Sigmoideal

Para esta função, os neurônios geram valores de ativação dentro do intervalo [0;1].

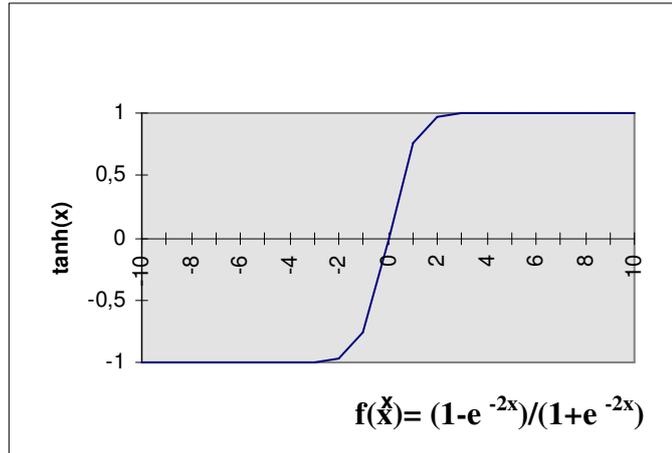


FIGURA 2.16 - Função Tangente Hiperbólica

Para esta função, os neurônios geram valores de ativação dentro do intervalo $[-1;1]$.

Assim:

$$i_{pj} = \text{sigm}^h(\text{net}_{pj}) \quad \text{ou} \quad i_{pj} = \text{tanh}^h(\text{net}_{pj}) \quad [2.24]$$

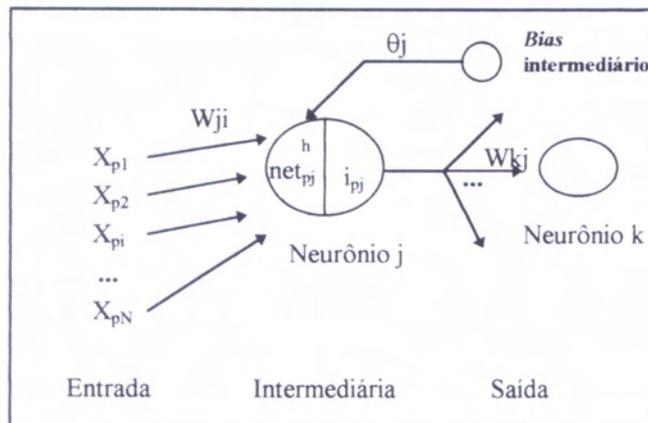


FIGURA 2.17 - Funcionamento dos neurônios da camada escondida.
Fase de propagação. Adaptação: FREEMAN & SKAPURA (1991)

5. Calcular os valores internos (net) para os neurônios (k) da camada de saída (o):

$$\text{net}_{pk}^o = \sum_{j=1}^L W_{kj}^o \cdot i_{pj}^o + \theta_k^o \quad [2.25]$$

sendo L o número de neurônios da camada intermediária (Figura 2.17) e θ_k^o o valor de limiar do neurônio k .

6. Calcular as ativações dos neurônios de saída de forma semelhante à camada escondida:

$$O_{pk} = f(\text{net}_{pk}^o) \quad [2.26]$$

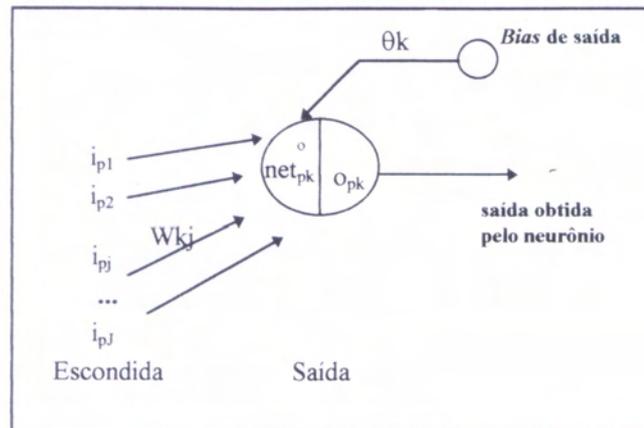


FIGURA 2.18 - Funcionamento dos neurônios da camada de saída. Fase de propagação. Adaptação: FREEMAN & SKAPURA (1991)

7. Calcular os termos de erro para as unidades de saída:

$$\phi_{pk}^o = (Y_{pk} - O_{pk}) \cdot f' \quad [2.27]$$

onde f' é a derivada da função de ativação escolhida. Para a função tangente hiperbólica, tem-se:

$$f' = \tanh'(x) = 1 - (\tanh(x))^2 \quad [2.28]$$

E, como para a camada de saída $\tanh(x) = O_{pk}$ (ver passo 6), obtém-se:

$$f' = \tanh'(x) = 1 - (O_{pk})^2 \quad [2.29]$$

Para a função de ativação sigmoidal, tem-se:

$$f' = \text{sigm}'(x) = \text{sigm}(x) \cdot (1 - \text{sigm}(x)) \quad [2.30]$$

E, de forma semelhante, obtém-se:

$$f' = \text{sigm}'(x) = O_{pk} \cdot (1 - O_{pk}) \quad [2.31]$$

8. Calcular os termos de erro para as unidades escondidas:

$$\phi_{pj} = f' \cdot \sum_{k=1}^U \phi_{pk} \cdot W_{kj} \quad [2.32]$$

onde U é o número de neurônios de saída, e:

$$f' = \text{tanh}'(x) = 1 - (\text{tanh}(x))^2 \quad [2.33]$$

substituindo-se a derivada, conforme o passo 4:

$$f' = 1 - (i_{pj})^2 \quad [2.34]$$

Ou, caso esteja-se trabalhando com uma RNA com função de ativação sigmoideal, tem-se:

$$f' = \text{sigm}'(x) = \text{sigm}(x) \cdot (1 - \text{sigm}(x)) = i_{pj} \cdot (1 - i_{pj}) \quad [2.35]$$

9. Atualizar pesos na camada de saída:

$$W_{kj}(t+1) = W_{kj}(t) + \eta \cdot \phi_{pk} \cdot i_{pj} \quad [2.36]$$

sendo η o coeficiente que determina a velocidade do aprendizado.

10. Atualizar pesos na camada escondida:

$$W_{ji}(t+1) = W_{ji}(t) + \eta \cdot \phi_{pj} \cdot X_{pi} \quad [2.37]$$

11. Repetir de 2 a 10 para os M padrões.

O processo se encerra quando o erro médio quadrado (EMQ), dos M padrões, for menor ou igual a um erro mínimo previamente estipulado, ou ao atingir-se um número determinado de iterações.

$$EMQ = 1/M \sum_{p=1}^M E_p \quad [2.38]$$

sendo E_p o erro instantâneo obtido ao apresentar o padrão X_p na entrada da rede. Este erro é dado por:

$$E_p = 1/2 \cdot \sum_{k=1}^U (Y_{pk} - O_{pk})^2 \quad [2.39]$$

2.3.2.3 Considerações gerais

Para o início do processo de aprendizado da RNA é necessário selecionar um conjunto de amostras das classes de padrões (conjunto de treinamento) a serem aprendidos e as saídas desejadas correspondentes. Amostras representativas e em número suficiente devem ser selecionadas para cada classe.

Em um segundo momento, os pesos, que representam as conexões entre neurônios, devem ser inicializados com valores aleatórios pequenos (± 0.5).

Outro requisito importante é a determinação de qual função de ativação será utilizada na rede. Em geral, a função tangente hiperbólica apresenta melhores resultados para o aprendizado, pois converge mais rapidamente. Porém, ao se trabalhar com esta função é necessário normalizar as entradas da rede para o intervalo $[-1;1]$, antes da propagação. Desta forma, as entradas e saídas da rede ficam compatíveis, ocupando o mesmo espaço vetorial. Caso a escolha seja a função sigmoideal é necessário normalizar as entradas para o intervalo $[0;1]$.

O algoritmo de *BackPropagation* baseia-se no Gradiente Descendente do Erro, ou seja, na minimização do erro médio quadrado. Porém, dependendo dos pesos iniciais, do número de neurônios intermediários e do coeficiente de aprendizado, pode acontecer da RNA atingir um mínimo local e não o mínimo global. Se este mínimo local significar um erro médio quadrado aceitável, o aprendizado está realizado; caso

contrário, é necessário continuar o treinamento. Para tanto, a fim de atingir-se um outro mínimo local ou até mesmo o mínimo global, é preciso adotar algumas medidas do tipo:

- Reiniciar o processo com novos pesos aleatórios;
- Alterar o coeficiente de aprendizado (em geral, diminuir)¹⁸ ;
- Aumentar o número de neurônios intermediários ou o número de camadas intermediárias¹⁹ .

Como visto, o valor do coeficiente de aprendizado tem efeito significativo sobre o desempenho da rede. Deve ser um valor pequeno, como 0.05 ou 0.25, para garantir que a rede atinja uma solução. Em contrapartida, um valor pequeno para este parâmetro implica um elevado número de iterações e, conseqüentemente, um maior tempo de processamento.

Entretanto, para acelerar a convergência pode-se utilizar a técnica do momento. Esta técnica consiste em acrescentar um termo adicional ($\Delta_p W(t-1)$), correspondente a uma fração do ajuste feito na iteração anterior, à atualização dos pesos. Isto tende a manter as mudanças dos pesos na mesma direção.

Desta forma, tem-se para os pesos da camada escondida:

$$\boxed{W_{ji}^h(t+1) = W_{ji}^h(t) + \eta \cdot \phi_{pj} \cdot X_{pi}^h + \alpha \Delta_p W_{ji}^h(t-1)} \quad [2.40]$$

sendo α (parâmetro do momento) um valor positivo e menor do que 1. α representa uma proporção da variação do peso no tempo t-1.

De forma semelhante, tem-se para a camada de saída:

$$\boxed{W_{kj}^o(t+1) = W_{kj}^o(t) + \eta \cdot \phi_{pk} \cdot i_{pj}^o + \alpha \Delta_p W_{kj}^o(t-1)} \quad [2.41]$$

¹⁸ HEERMANN & KHAZENIE (1992) sugere que o coeficiente de aprendizado seja igual a 1/n, onde n é o número total de nodos da rede.

¹⁹ Após o aprendizado, é possível retirar as unidades escondidas supérfluas. Considera-se unidade (neurônio) supérflua aquela cujo peso modifica-se muito pouco durante o treinamento.

Como considerações finais, nota-se que:

- A camada de entrada da rede tem por finalidade única repassar os padrões de entrada para os neurônios intermediários. Logo, nesta camada nenhum cálculo (processamento) é realizado;
- Durante o treinamento é importante selecionar, aleatoriamente, os padrões, de modo a não treinar a rede completamente com um padrão e depois passar para um outro. A aleatoriedade não permite que a rede esqueça o padrão anterior.

A próxima seção apresenta uma breve comparação entre as Redes Neurais e o método de Máxima Verossimilhança Gaussiana na classificação de imagens multi-espectrais. Além disto, algumas aplicações de Redes Neurais, na área de Sensoriamento Remoto, são citadas.

2.4 Máxima Verossimilhança Gaussiana *Versus* Redes Neurais

Segundo BISCHOF et. al (1992), a análise de imagens multi-espectrais é, tradicionalmente, realizada por classificadores que se baseiam no Teorema de Bayes. Os classificadores Bayesianos são, teoricamente, ideais quando as hipóteses sobre as distribuições de probabilidade são corretas, para as diversas classes existentes na imagem. Entretanto, a necessidade de obter-se um modelo probabilístico específico é a maior limitação desta abordagem. Assim, uma classificação pobre pode ser obtida, se as probabilidades de densidade são diferentes daquelas assumidas pelo modelo.

Usualmente, utiliza-se o modelo de Máxima Verossimilhança Gaussiana que é um classificador Bayesiano com distribuição de probabilidade gaussiana. Desta forma, considera-se que as distribuições internas de cada classe da imagem, a ser classificada, possui distribuição normal (BISCHOF et al., 1992).

Entretanto, conforme SEIBERT (1992), nem sempre, os dados das imagens multi-espectrais apresentam distribuição de probabilidade gaussiana e, portanto,

classificadores gaussianos não seriam a melhor técnica de classificação para estas imagens.

As RNA's são uma alternativa para uma variedade de problemas de classificação. Publicações recentes, como AN et al. (1995), MACHADO (1993), ENGEL (1993), HEERMANN & KHAZENIE (1992) e BISCHOF et al. (1992), têm mostrado o sucesso das aplicações de Redes Neurais para a classificação de imagens multi-espectrais de satélites de Sensoriamento Remoto.

Classificações de tipos de rochas por *BackPropagation*, na região do norte do Canadá, são apresentadas em AN et al. (1995). Além dos resultados da classificação, este estudo apresenta uma análise sobre a importância de obter-se uma quantidade suficiente de amostras significativas, para as etapas de treinamento e reconhecimento de uma Rede Neural Artificial, com a finalidade de obter-se uma classificação satisfatória.

MACHADO (1993) utiliza *BackPropagation* para classificar áreas na Amazônia. Neste estudo, imagens do *LANDSAT-TM* que cobrem esta região são classificadas em: floresta, cerrado, água, área desflorestada, nuvem, sombra e bruma.

HEERMANN & KHAZENIE (1992) apresenta um estudo focalizado na classificação de tipos de vegetação nos arredores de Chernobyl. Além de classificar esta região em floresta, agricultura, área urbana, água e nuvem, uma importante conclusão é apresentada: existe uma correlação positiva entre a acurácia da classificação e o tamanho do conjunto de treinamento, ou em outras palavras, o uso de um número maior de bandas (mais de três) pode melhorar a classificação, no momento em que o comportamento espectral pode ser melhor distinguido. Este estudo utiliza uma Rede Neural Multinível com *BackPropagation* Adaptativo, onde uma das finalidades é a de acelerar a fase de aprendizado da rede.

De maneira semelhante, BISCHOF et al. (1992) realiza a aplicação de uma rede *BackPropagation*, de três níveis, para a classificação de imagens de satélite em uma base *pixel-a-pixel*. Cenas do *LANDSAT-TM*, dos arredores de Viena, foram classificadas em: área urbana, área agrícola, floresta e água.

Além disto, é possível utilizar-se *BackPropagation* na classificação de imagens multi-espectrais, para supervisionar e interpretar danos em florestas, contribuindo de forma destacada na área de proteção ambiental (ENGEL, 1993).

A habilidade de aprendizado em RNA's fornecem um interesse alternativo aos classificadores Bayesianos. Por não ser necessário definir um modelo de probabilidade, as RNA's são ditas universais.

Algumas desvantagens da classificação por técnicas convencionais em relação às técnicas de Redes Neurais são relatadas em VASCONCELOS (1995). Entre elas, pode-se dizer que um classificador Bayesiano necessita de suposições teóricas a respeito da distribuição de probabilidade das classes de padrões, o que dificilmente é observado na prática.

Em contrapartida, as RNA's são técnicas não-paramétricas, que podem ser utilizadas para estimar uma função de mapeamento entre padrões de entrada e classes (padrões de saída) associados, com o uso de um conjunto de pares de treinamento (AN et al., 1995).

Trabalho encontrado em SEIBERT (1992), cujo objetivo era diferenciar áreas arborizadas intactas de áreas devastadas devido a tempestades, expõe alguns resultados superiores de acurácia obtidos por classificadores neurais sobre métodos convencionais. Neste trabalho, o autor relata que resultados obtidos com Redes Neurais, como *BackPropagation* e Mapas de Características de *Kohonen*, mostraram ser mais favoráveis do que classificações por Máxima Verossimilhança e outros classificadores convencionais. Isto se deve ao fato de que o método clássico de Máxima Verossimilhança é baseado em condições matemáticas inflexíveis, quando em geral, *BackPropagation* é apta a determinar áreas no espaço de características com boa exatidão.

Devido a grande viabilidade e utilidade das Redes Neurais Artificiais na classificação de imagens multi-espectrais, a presente pesquisa emprega e valida esta técnica em uma situação real no estado do Rio Grande do Sul, Brasil.

Pretende-se identificar espécies vegetais de *Eucalyptus*, *Acácia mearsii* e *Mata Nativa* de grande interesse econômico para a região.

A próxima seção aborda o geo-referenciamento de imagens multi-espectrais. Este processo foi utilizado, antes da classificação de parte da área de estudo, como meio de localizar pontos no terreno que pudessem ser utilizados no treinamento dos classificadores supervisionados.

2.5 Geo-referenciamento

2.5.1 O que é?

Conforme CRÓSTA (1992), o Geo-referenciamento é a transformação de uma imagem para que ela assuma as propriedades de escala e de projeção de um mapa. Ou, em outras palavras, geo-referenciamento é um procedimento que estabelece uma relação entre uma imagem e um sistema de coordenadas de referência universalmente conhecido (EASTMAN, 1996).

Assim, geo-referenciar uma imagem consiste em obter novas posições para os seus *pixels*, de maneira que se introduza, na imagem, a precisão cartográfica do sistema de referência escolhido. Desta maneira, eliminam-se distorções de escala, provocadas pelo movimento de rotação da Terra, determina-se, com certa precisão, a distância entre dois alvos da superfície terrestre e é possível conhecer a posição aproximada no terreno de um *pixel* na imagem, ou vice-versa.

Pode-se descrever este procedimento nos próximos três passos:

PASSO 1: ESCOLHA DO SISTEMA DE COORDENADAS DE REFERÊNCIA

Entende-se como sistema de referência, as coordenadas de Latitude/Longitude e as coordenadas UTM (*Universal Transversa Mercator*), que podem ser encontradas em mapas, cartas do exército ou em outra imagem previamente geo-referenciada.

PASSO 2: OBTENÇÃO DOS PARÂMETROS DO MODELO QUE ESTABELECE A RELAÇÃO ENTRE A IMAGEM E O SISTEMA DE COORDENADAS DE REFERÊNCIA

É necessário estabelecer um modelo, cujas equações relacionem a posição de um ponto na imagem com sua respectiva posição geográfica. Para tanto, um conjunto de pontos de controle precisa ser adquirido. Cada ponto é constituído pelos pares de coordenadas (X_i, Y_i) e (X_T, Y_T) . O par (X_i, Y_i) representa a posição do ponto na imagem de satélite (coordenadas de linha e coluna), enquanto que o par (X_T, Y_T) representa a posição, do mesmo ponto, no sistema de referência. A Figura 2.19 ilustra valores para coordenadas (X_i, Y_i) e (X_T, Y_T) , para três pontos de controle, considerando uma imagem e um mapa exemplo.

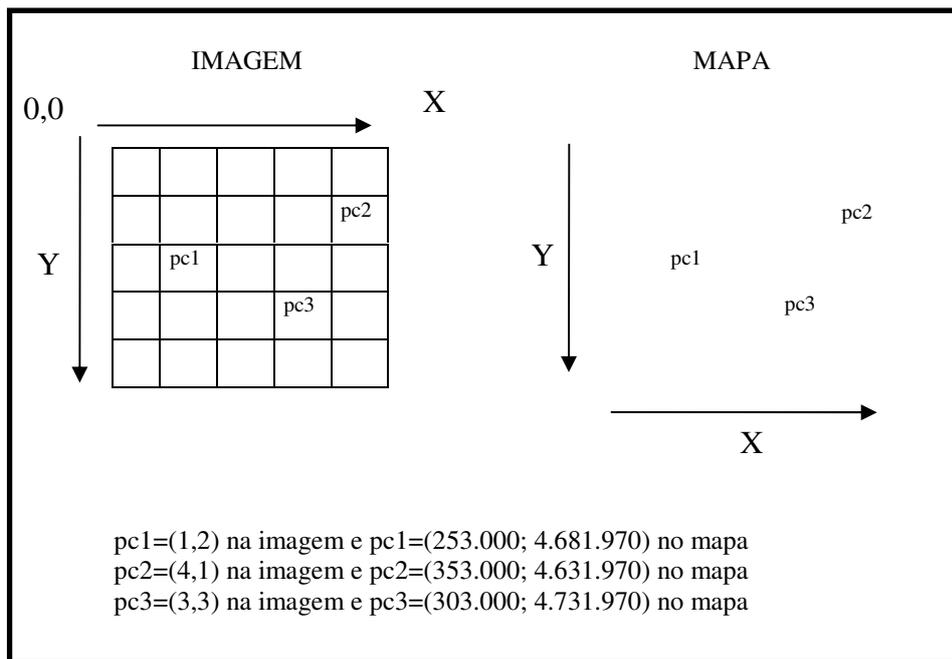


FIGURA 2.19 - Exemplo de pares de pontos de controle.
 Adaptação: EASTMAN (1996)

Após, os pontos de controle são substituídos nas equações do modelo escolhido. Desta forma, os parâmetros que descrevem o modelo podem ser determinados.

Em geral, utiliza-se o modelo Linear ou o modelo Quadrático.

O modelo Linear é dado por:

$$\begin{aligned}
 X_{T0} &= aX_{i0} + bY_{i0} + c \\
 Y_{T0} &= dX_{i0} + eY_{i0} + f \quad (6 \text{ parâmetros e } K \text{ pontos de controle}) \\
 &\dots \\
 X_{Tk} &= aX_{ik} + bY_{ik} + c \\
 Y_{Tk} &= dX_{ik} + eY_{ik} + f
 \end{aligned}
 \tag{2.42}$$

O modelo Quadrático é dado por:

$$\begin{aligned}
 X_{T0} &= aX_{i0} + bY_{i0} + cX_{i0}Y_{i0} + dX_{i0}^2 + eY_{i0}^2 + f \\
 Y_{T0} &= gX_{i0} + hY_{i0} + iX_{i0}Y_{i0} + jX_{i0}^2 + lY_{i0}^2 + m \\
 &\dots \quad (12 \text{ parâmetros e } K \text{ pontos de controle})
 \end{aligned}$$

$$\begin{aligned} X_{Tk} &= aX_{ik} + bY_{ik} + cX_{ik}Y_{ik} + dX_{ik}^2 + eY_{ik}^2 + f \\ Y_{Tk} &= gX_{ik} + hY_{ik} + iX_{ik}Y_{ik} + jX_{ik}^2 + lY_{ik}^2 + m \end{aligned} \quad [2.43]$$

Nota-se que para a resolução do conjunto de equações do modelo linear são necessários, no mínimo, três pontos de controle. Já para a determinação dos doze parâmetros do modelo quadrático são necessários pelo menos seis pontos.

Com os parâmetros do modelo conhecidos²⁰, é possível prever a localização aproximada, no terreno, para qualquer ponto na imagem de satélite, ou vice-versa, caso o modelo seja invertido para: $(X_i, Y_i) = f(X_T, Y_T)$.

Como os valores fornecidos pelo modelo são aproximados, existe um erro, ou resíduo, entre o valor correto e o predito. Assim, a idéia consiste em encontrar um conjunto de pontos de controle que minimize o erro médio quadrado (E). Para todos os pontos, o erro médio quadrado é dado por:

$$E = 1/N \sum_{i=1}^N ((X_p - X_T)^2 + (Y_p - Y_T)^2)^{1/2} \quad [2.44]$$

onde N é o número de pontos de controle adquiridos, X_p e Y_p são os valores preditos pelo modelo e, X_T e Y_T são os valores corretos, no terreno.

Um erro médio quadrado inferior a um *pixel* (< 30, para o *LANDSAT 5-TM*) é considerado satisfatório (CRÓSTA, 1992).

PASSO 3: CONVERSÃO DA IMAGEM PARA O NOVO SISTEMA DE REFERÊNCIAS

Com a aplicação do modelo, cada um dos *pixels* da imagem original são realocados para a sua nova posição na imagem geo-referenciada. Porém, considerando-se $(X_i, Y_i) = f(X_T, Y_T)$, as coordenadas X_i e Y_i obtidas são, muitas vezes, valores reais e não inteiros (JENSEN, 1986). A Figura 2.20 ilustra um exemplo hipotético, considerando $X_T=4$ e $Y_T=5$ ²¹. Nota-se que neste caso, X_i e Y_i assumem os valores 2.7 e 2.4, respectivamente, mantendo-se no meio de quatro *pixels*, na imagem original.

²⁰ Os parâmetros podem ser obtidos passando as equações do modelo para o formato matricial: $T=M*P$. Logo: $P = (M^t M)^{-1} M^t T$, onde P é o vetor de parâmetros, M é a matriz com os pontos da imagem e T é o vetor com os pontos do terreno. t e -1 correspondem à matriz transposta e inversa, respectivamente.

²¹ Uma grade retangular, que equivale ao arranjo de *pixels* da imagem geo-referenciada, é sobreposta ao mapa de referência para a obtenção das coordenadas discretas.

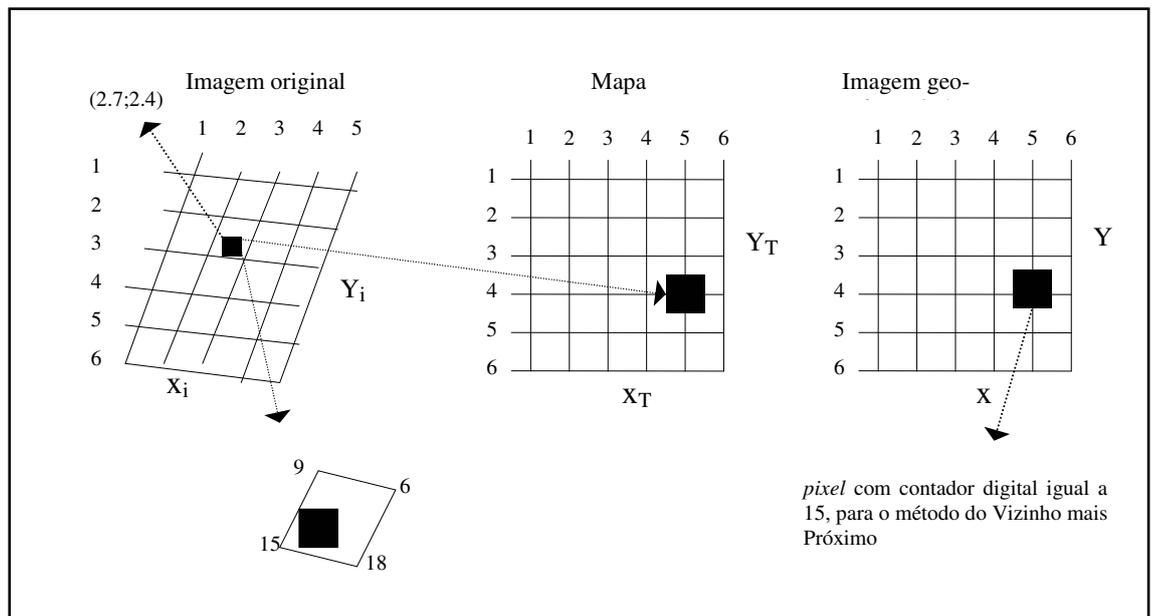


Figura 2.20 - Exemplo de geo-referenciamento (imagem x mapa).
Adaptação: JENSEN (1986)

Em função disto, surge a seguinte questão: qual o contador digital a ser atribuído para a posição (4,5) na imagem geo-referenciada?²² Para resolver este problema, utiliza-se métodos de interpolação de valores de contadores digitais, tais como: Vizinho mais Próximo, Interpolação Bilinear e Convulação Cúbica. Salienta-se que, na prática, denomina-se Amostragem este processo de recalculando os valores dos contadores digitais para a imagem geo-referenciada (JENSEN, 1986).

Conforme JENSEN (1986), no método do Vizinho mais Próximo, o novo contador digital do *pixel* é dado pelo valor mais próximo do seu centro²³, na imagem original. Conforme o exemplo da Figura 2.20, para este método, o contador digital atribuído ao *pixel* (4,5), da imagem geo-referenciada, seria 15. Nota-se que as intersecções entre as linhas representam os *pixels* da imagem. Logo, os *pixels* (2,2), (2,3), (3,2) e (3,3), da imagem original, possuem os contadores digitais 9, 6, 15 e 18, respectivamente. Como vantagem, este método é computacionalmente eficiente, além de não alterar os contadores digitais originais durante a amostragem (JENSEN, 1986).

²² Lembra-se que, neste processo, a imagem geo-referenciada herda as características do mapa de referência (JENSEN, 1986).

²³ Pode-se utilizar a distância Euclidiana que é dada por: $((X_a - X_b)^2 + (Y_a - Y_b)^2)^{1/2}$, sendo a e b dois pontos quaisquer.

Entretanto, como desvantagem, os contadores digitais se repetem gerando uma imagem sem muita estética (CRÓSTA, 1992).

No método de Interpolação Bilinear, o novo valor do *pixel* é obtido da média ponderada pelas distâncias dos quatro vizinhos mais próximos do centro do novo *pixel*. Este método produz uma imagem suavizada, porém o tempo de computação é mais elevado e, em geral, há perda do contraste, pois as bordas são suavizadas (CRÓSTA, 1992; JENSEN, 1986).

Já no método de Convolução Cúbica, o valor do novo *pixel* é calculado com base nos dezesseis vizinhos mais próximos. Neste caso, é feito um ajuste de uma superfície polinomial de 3º grau (bidimensional) à região, de modo a circundar o *pixel* em questão. Este método produz uma imagem com aparência mais natural, porém há perda de algumas feições de alta frequência²⁴ (CRÓSTA, 1992; RICHARDS, 1986).

A escolha do método de interpolação depende do uso a ser feito da imagem e do tempo computacional disponível. Para uso de classificação, sugere-se o Vizinho mais Próximo, já que este método é o que preserva o valor original dos *pixels*, pois estes são, simplesmente, rearranjados em uma nova posição geometricamente correta (RICHARDS, 1986). Para fins de análise visual, tanto o método Bilinear quanto a Convolução Cúbica são indicados (CRÓSTA, 1992).

2.5.2 Considerações

Convém salientar que a precisão do geo-referenciamento depende da quantidade, da distribuição e da precisão com que se obtém os pontos de controle. O ideal é obter o maior número possível de pontos que sejam perfeitamente identificáveis, tanto no sistema de referência quanto na imagem. Em geral, bons pontos de controle estão localizados na intersecção de estradas e rios, nas pistas de aeroportos, em edifícios proeminentes, em topos de montanhas, nos limites de feições agrícolas (campos semeados), em intersecções de drenagens, enfim, naquelas feições bem definidas, geralmente de grande contraste em relação aos seus arredores (EASTMAN, 1996; CRÓSTA, 1992).

Quanto à distribuição, os pontos de controle devem estar uniformemente distribuídos, a fim de que o modelo ajuste, corretamente, toda a imagem e não, apenas,

²⁴ Qualquer interpolação é, na verdade, um filtro de passa-baixa (CRÓSTA, 1992).

parte dela. Porém, se o interesse está em parte da imagem, deve-se concentrar todos os pontos nesta área e, após o geo-referenciamento, desconsidera-se o restante da imagem (CRÓSTA, 1992; JENSEN, 1986).

A precisão em determinar a localização dos pontos talvez seja a questão mais crítica deste procedimento. Devido a resolução do *pixel*, é difícil determinar a localização precisa do ponto de controle na imagem. O mesmo ocorre na obtenção dos pontos, no sistema de referência, através de uma mesa digitalizadora. E, é justamente esta falta de precisão que acarreta um erro médio quadrado elevado. Assim sendo, convém analisar os resíduos obtidos, antes de converter a imagem para o sistema de referência, e omitir os pontos que apresentarem alto grau de erro de posicionamento, pois, sem dúvida, estes pontos foram mal escolhidos.

Nota-se que em áreas onde não existem mapas, a alternativa é medir precisamente, no terreno, a posição geográfica de alguns pontos identificáveis na imagem, usando um GPS (*Global Position System*). Porém, esta alternativa representa um custo bastante elevado (CRÓSTA, 1992).

Por fim, o geo-referenciamento pode ser realizado antes ou depois da classificação da imagem. A vantagem em geo-referenciar antes está na possibilidade de adquirir dados de campo que auxiliem na classificação, visto que seria possível localizar determinados *pixels* no terreno. Porém, como desvantagem, este procedimento acrescenta incertezas aos valores dos contadores digitais, devido aos métodos de interpolação, prejudicando a exatidão da classificação. Conforme RICHARDS (1986), a regra é: sempre que possível geo-referenciar a imagem após a classificação; porém, se for necessário geo-referenciar antes, utilizar o Vizinho mais Próximo como método de interpolação.

Maiores informações sobre geo-referenciamento podem ser encontradas em EASTMAN (1996), DEPPE (1995), CRÓSTA (1992), RICHARDS (1986) e JENSEN (1986).

A próxima seção apresenta um relato sobre o comportamento espectral da vegetação (considerando tanto uma folha individual quanto toda uma comunidade vegetal), além de sugerir como selecionar as bandas a serem utilizadas em uma classificação digital.

2.6 Comportamento espectral da vegetação

Esta seção apresenta a estrutura interna e o comportamento espectral de uma folha individual típica para, após, expandir os conceitos para o estudo de uma comunidade vegetal. As informações aqui contidas foram obtidas de FONTANA (1995), ASSUNÇÃO & FORMAGGIO (1989) e SWAIN & DAVIS (1978).

2.6.1 Estrutura de uma folha típica

Para um bom entendimento do comportamento espectral da vegetação, é necessário o conhecimento da estrutura interna de uma folha individual. Para tanto, um corte transversal, feito em uma folha, permite observar sua estrutura interna, como mostra a Figura 2.21.

A folha é envolta por uma cutícula fina que tem por função proteger e realizar as trocas gasosas, recebendo gás carbônico e liberando oxigênio.

Internamente à cutícula, existe uma camada de células, muito unidas e freqüentemente desprovidas de clorofila, denominada epiderme.

Entre a epiderme superior e a epiderme inferior há uma região denominada mesófilo, formada por células ricas em cloroplastos²⁵. Estes são impregnados por pigmentos verdes chamados de clorofila. A clorofila absorve a luz solar e transforma o dióxido de carbono, a água e os sais minerais (estes últimos provenientes do solo) em matéria orgânica²⁶ (açúcares, gorduras, proteínas e outros), enquanto liberam oxigênio. Em outras palavras, é a clorofila o elemento responsável pelo processo de fotossíntese, ou elaboração de alimentos, quando da existência de luz solar ou artificial. Cerca de 65% dos pigmentos encontrados nos cloroplastos são clorofilas do tipo a e b. Os outros 35% são pigmentos chamados de carotenóides²⁷ (carotenos - 6% e xantofilas - 29%).

²⁵ Conforme Assunção & Formaggio (1989), cloroplastos são partículas subcelulares, genericamente denominadas organelas, que ocorrem nos tecidos verdes das plantas, em maior número nas células do mesófilo das folhas e são responsáveis pelo processo fotossintético.

²⁶ Parte desta matéria orgânica é usada para o próprio desenvolvimento da planta e o excesso é guardado nas raízes e caules servindo, muitas vezes, para a alimentação humana, como é o caso da mandioca, da batatinha e da maçã.

²⁷ Estes pigmentos dão a cor amarelada, alaranjada ou, até mesmo, avermelhada aos vegetais, devido ao processo de oxidação dos pigmentos.

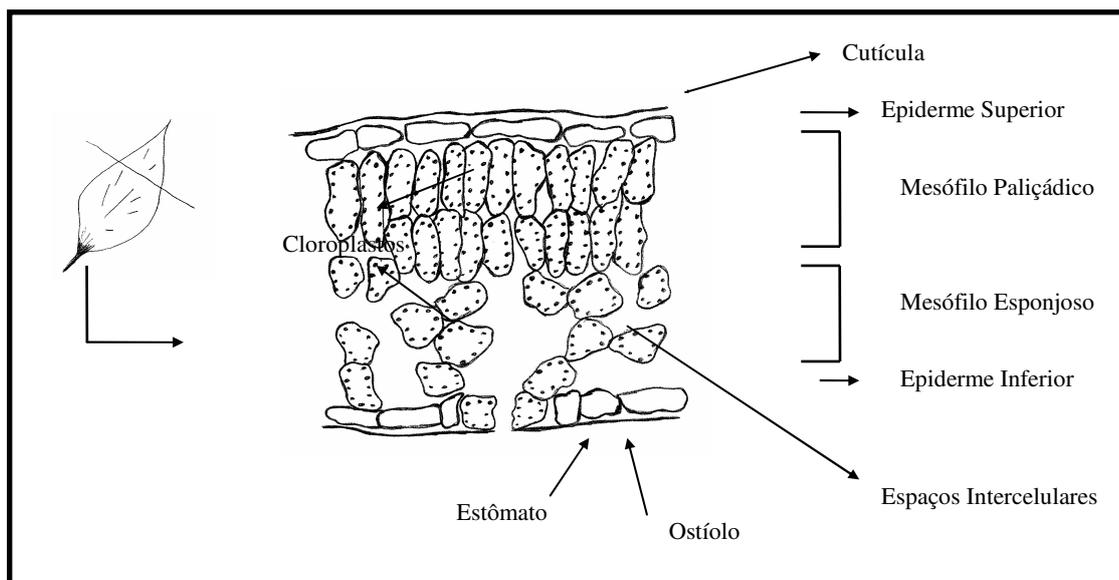


FIGURA 2.21 - Estrutura interna de uma folha típica.

Fonte: ASSUNÇÃO & FORMAGGIO (1989)

O mesófilo é composto por dois parênquimas²⁸: paliádico e esponjoso. No parênquima paliádico, as células são alongadas, bem organizadas, fortemente unidas e perpendiculares à superfície da folha, enquanto que no parênquima esponjoso, as células são mais arredondadas, se distribuindo irregularmente e com grandes espaços vazios entre si. São estes espaços vazios que proporcionam as áreas necessárias às trocas gasosas para a fotossíntese e respiração da planta.

Nas células da epiderme inferior existem poros microscópicos denominados estômatos. Estes poros são formados por duas células epidérmicas repletas de cloroplastos. Quando os poros se abrem, aparece uma fenda denominada ostíolo, que permite a entrada de ar e a saída de água. Logo, através dos estômatos, a planta respira (absorve O₂ dissolvido em água), transpira (deixa escapar grande quantidade de água em forma de vapor ou gotículas) e absorve o CO₂ necessário à fotossíntese.

Cabe salientar que esta estrutura típica varia conforme a espécie vegetal e a condição ambiental. Assim, folhas cujas posições são paralelas aos raios solares têm pouca ou quase nenhuma diferenciação entre os lados dorsal e ventral.

²⁸ Tecidos celulares.

2.6.2 Comportamento espectral de uma folha individual

O comportamento espectral típico de uma folha verde é mostrado na Figura 2.22.

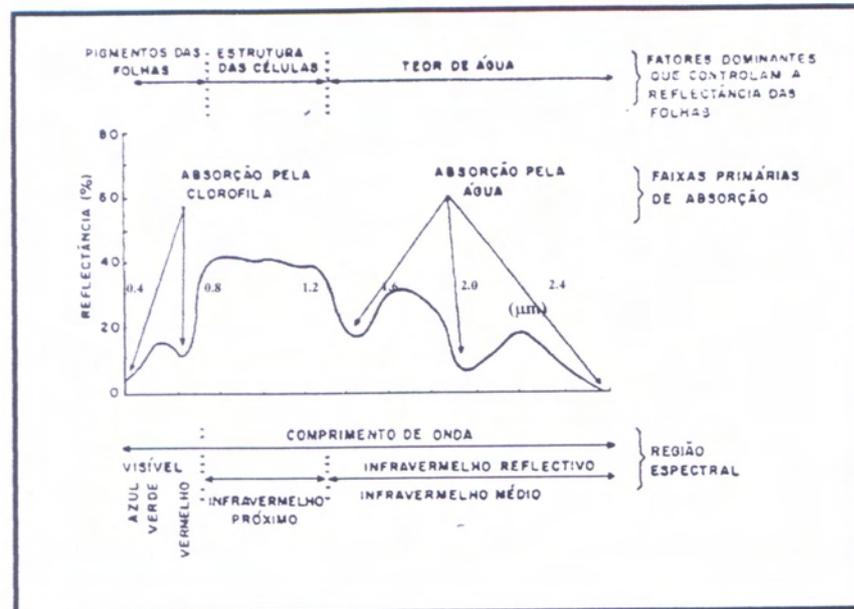


FIGURA 2.22 - Comportamento espectral de uma folha individual.
Fonte: ASSUNÇÃO & FORMAGGIO (1989)

Conforme a Figura 2.22, é possível observar que o comportamento espectral varia conforme o comprimento de onda, proveniente dos raios solares, que incide sobre a folha. Em geral, as folhas possuem alta absortância nas regiões do ultravioleta (0.01-0.39 μm), do azul (0.43-0.50 μm), do vermelho (0.6-0.76 μm) e do IV médio (1.35-2.6 μm). Consequentemente, nas regiões do verde (0.5-0.6 μm) e do IV próximo (0.76-1.35 μm) há alta reflectância. Esta variação de absortância, reflectância e transmitância²⁹ depende dos pigmentos contidos nos cloroplastos, da estrutura interna e da quantidade de água presente na folha.

Nota-se que a maior parte das informações de reflectância das folhas estão contidas no intervalo entre 0.4 e 2.7 μm . Fora desta região, a reflectância é muito baixa e relativamente uniforme, geralmente, inferior a 5%.

Na parte visível do espectro, que corresponde aos comprimentos de onda de 0.4 a 0.76 μm , cerca de 90% da energia incidente é absorvida, menos de 10% é refletida

²⁹ Ver Anexo 02 para explicações mais detalhadas sobre os conceitos de absortância, reflectância e transmitância.

e o restante é transmitida pela folha. A alta absorvência se dá, principalmente, nos comprimentos de onda do azul (0.4 a 0.5 μm) e do vermelho (0.6 a 0.7 μm), pois a energia contida nestes comprimentos de onda é utilizada para as atividades dos pigmentos (clorofila a, clorofila b e carotenóides) existentes nos cloroplastos. Quanto maior é a quantidade de pigmentos nas folhas, principalmente de clorofila (responsável pela fotossíntese), maior é a absorvência do azul e do vermelho. O verde acaba por ser o comprimento de onda de maior reflectância, caracterizando a própria coloração da folha.

A resposta espectral no visível depende não somente da quantidade de pigmentos, mas, também, do seu tipo. Segundo ASSUNÇÃO & FORMAGGIO (1989), experimentos realizados com *Coleus* verificaram que folhas sem pigmentos possuem alta reflectância no visível e, conseqüentemente, coloração esbranquiçada; folhas com antocianina³⁰ e sem clorofila refletem altamente o vermelho e absorvem o azul e o verde, adquirindo coloração avermelhada; folhas apenas com clorofila refletem o verde, absorvendo o azul e o vermelho, possuindo coloração esverdeada e folhas com clorofila e antocianina absorvem, em grandes quantidades, o verde, o azul e o vermelho, apresentando coloração escura (Figura 2.23).

Na faixa do infravermelho (IV) próximo, o comportamento espectral já difere bastante. Nesta faixa do espectro, que vai de 0.76 a 1.35 μm , os pigmentos tornam-se altamente transparentes à radiação e, por conseqüência, da energia que incide sobre a folha, cerca de 45-50% é transmitida, cerca de 45-50% é refletida e menos de 5% é absorvida. Esta alta reflectância é resultante dos espaços intercelulares no mesófilo. A radiação chega às células do mesófilo e aos espaços intercelulares, onde é espalhada, devido a diferenças entre os índices de refração do ar (1,0) e das paredes celulares (1,4).

³⁰ Grupo de pigmentos que dão a coloração vermelho-púrpura às folhas.

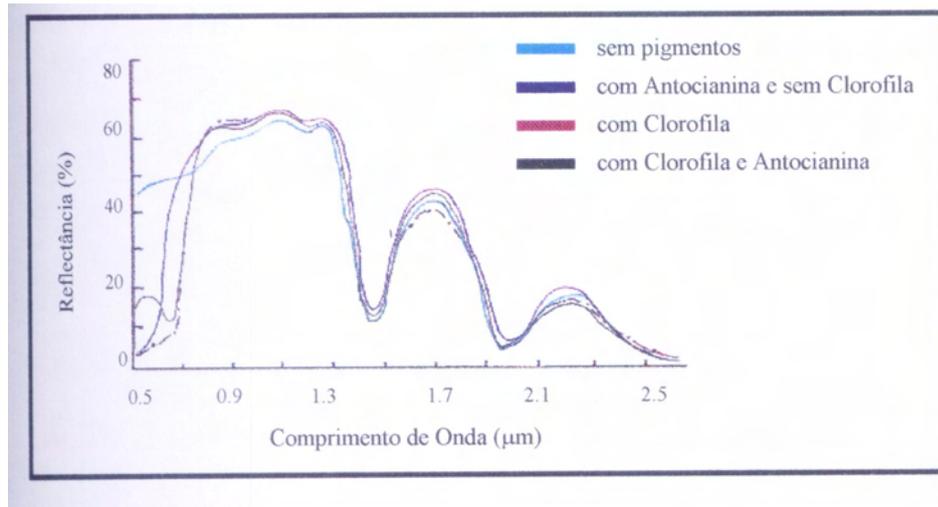


FIGURA 2.23 - Efeito de diferentes pigmentos no comportamento espectral de folhas de coleus. Fonte: SWAIN & DAVIS (1978)

Entretanto, quanto maior é a quantidade de água no interior da planta, menor é a reflectância nesta região (Figura 2.24). Isto ocorre, pois a infiltração de água diminui os espaços vazios, formando um meio líquido, e, por conseguinte, os índices de refração ficam mais parecidos, diminuindo o espalhamento da energia incidente e aumentando a transmitância.

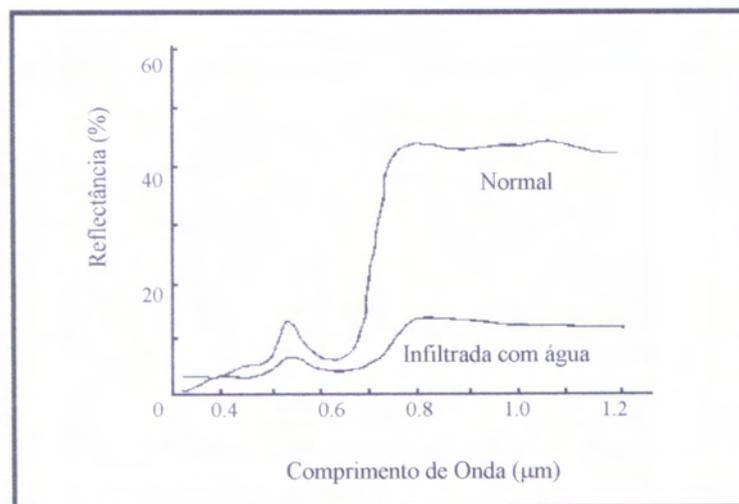


FIGURA 2.24 - Efeito do teor de umidade no comportamento espectral de folhas de feijão. Fonte: ASSUNÇÃO & FORMAGGIO (1989)

A faixa do IV médio, que vai de 1.35 a 2.60 μm , é caracterizada pelas bandas de absorção da água, cujos picos principais se encontram em: 1.4, 1.9 e 2.7 μm .

Uma folha sadia possui um bom teor de umidade e, assim, as bandas de absorção de água são bem pronunciadas. A Figura 2.26 mostra os picos de absorção da água e os picos de reflectância. Estes últimos se encontram em 1.6 e 2.2 μm e são inferiores a 30% para uma folha típica.

O quanto de energia é absorvida depende da quantidade total de água existente, que é função do teor de umidade e da espessura da folha. Quanto menor é o teor de umidade, maior é a reflectância na região do IV médio. Entretanto, caso o teor de umidade se torne muito baixo (por volta de 50%), pode ocorrer alterações nas regiões do visível e do IV próximo, pois ocorre a degradação da clorofila e da própria estrutura celular.

2.6.3 Comportamento espectral de uma comunidade vegetal

A reflectância de uma comunidade vegetal é diferente da reflectância de uma simples folha. Isto acontece, pois na comunidade vegetal a resposta espectral obtida é influenciada pela superfície de fundo (solo), por alterações na própria vegetação e por fatores externos (meteorológicos, de iluminação da cena) que influenciam na reflectância das folhas que compõem a comunidade.

Assim, a análise do comportamento espectral da vegetação, em imagens de satélite, é complexa, pois são vários os fatores a influenciar na resposta espectral. Entre eles, é possível citar:

- Diferentes espécies, estágios de desenvolvimento e incidências de pragas;
- Diferentes tipos de solo, textura, umidade, manejo e práticas agrícolas;
- Relevo e ângulo de elevação solar;
- Fenômenos meteorológicos: seca, geada e enchentes;
- Bruma e poluição.

Todos estes fatores acabam por influenciar na quantidade de energia que chega até a vegetação e na que é refletida por ela e captada pelo sensor do satélite.

Em especial, cabe salientar, que a influência espectral do solo é maior nas primeiras fases do desenvolvimento da comunidade. Entretanto, quando a vegetação atinge o seu total desenvolvimento, sendo a interferência do fundo irrelevante, a

resposta espectral da comunidade passa a depender mais de suas próprias características, tais como: pigmentos, estrutura das folhas e quantidade de água.

Conforme ASSUNÇÃO & FORMAGGIO (1989), com o crescimento vegetal há um aumento na reflectância no IV próximo, devido ao efeito da reflectância aditiva, e um simultâneo decréscimo da reflectância no visível, pela maior densidade de pigmentos (pois existe um número maior de folhas). Assim, plantas jovens, com poucas folhas, absorvem menos o azul e o vermelho do que plantas adultas, que possuem um número maior de pigmentos. Já na região do IV próximo, as plantas adultas refletem mais do que as jovens, devido ao processo de reflectância aditiva causado pela sobreposição de camadas de folhas.

O processo de reflectância aditiva, também denominado fator de compensação, pode ser descrito da seguinte maneira: da energia recebida por uma camada superior de folhas (camada 1), uma parte é transmitida para a camada logo abaixo (camada 2) e a outra parte é refletida; o mesmo ocorre com a camada abaixo (camada 2); parte da energia que recebe é transmitida e parte é refletida de volta para a camada superior; este processo continua sucessivamente conforme o número de camadas de folhas existente. Conforme a Figura 2.25, da energia incidente, cerca de 62,5% é refletida pela camada superior. Nota-se que neste exemplo, apenas duas camadas de folhas estão sendo consideradas.

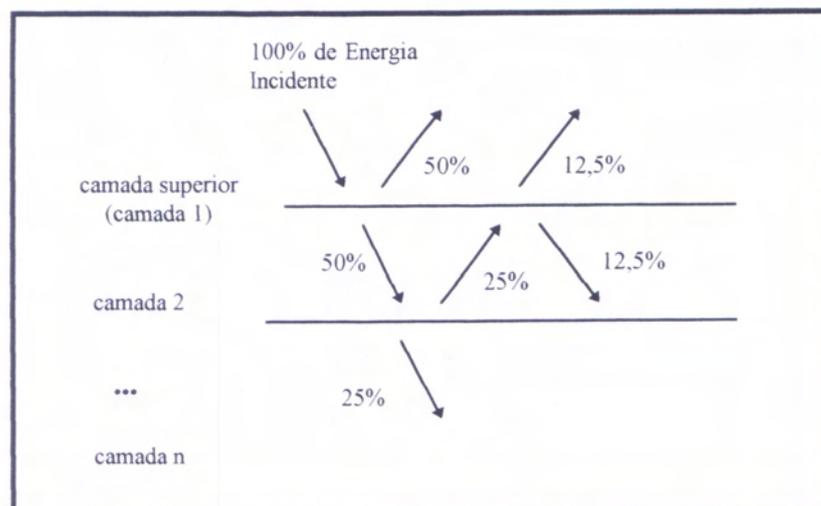


FIGURA 2.25 - Processo de Reflectância Aditiva.
Fonte: ASSUNÇÃO & FORMAGGIO (1989)

Durante a época que vai da maturidade até a senescência, mudanças estruturais ocorrem na planta e o comportamento espectral é alterado, apresentando as seguintes características:

- Baixo contraste entre o visível e o IV próximo;
- O decréscimo da umidade provoca mudanças na pigmentação e na estrutura do mesófilo;
- Os pigmentos carotenóides passam a ser dominantes e, conseqüentemente, o vermelho é menos absorvido, o que acaba por alterar a própria coloração da folha que se torna amarelada (resultado da reflexão do verde e do vermelho);
- Diminui o espalhamento devido à diminuição do número de paredes celulares e dos espaços vazios da planta. Logo, há uma diminuição na reflectância do IV próximo.

Por fim, como mostra a Figura 2.26, a vegetação apresenta um comportamento espectral bastante distinto dos demais alvos da superfície terrestre, tais como solo e água.

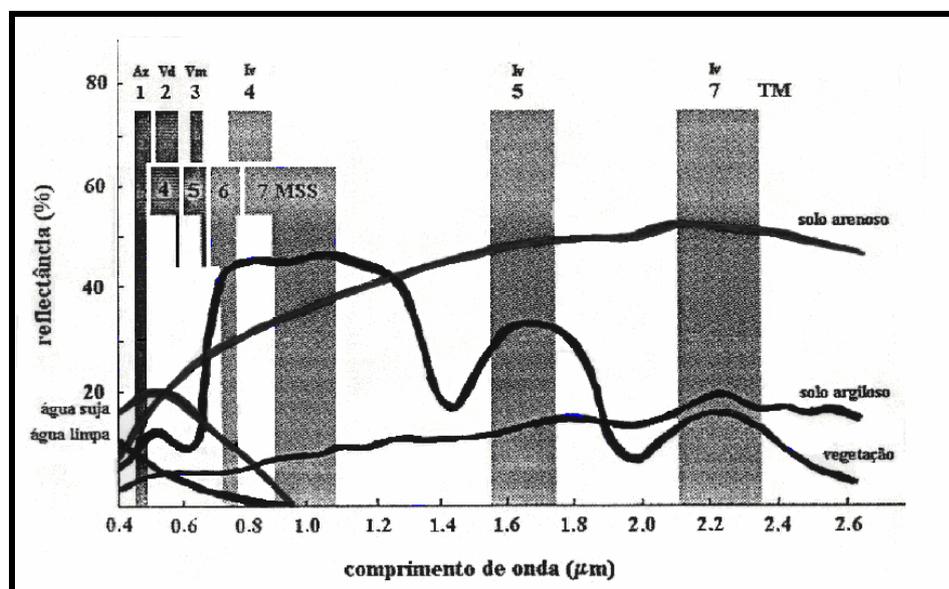


FIGURA 2.26 - Relação entre as faixas espectrais dos sensores *LANDSAT TM* e *LANDSAT MSS* e a reflectância espectral de alvos da superfície terrestre. Adaptação: RICHARDS (1986)

2.6.4 Seleção de bandas do *LANDSAT 5-TM* para estudo da vegetação

A escolha das bandas, a serem utilizadas em uma classificação, depende do tipo da aplicação que está sendo realizada. Esta escolha deve ser cuidadosa, no momento em que se deseja o melhor resultado possível em uma classificação digital. A Tabela III sugere o uso de determinadas bandas para algumas aplicações específicas.

Porém, cabe salientar que existem métodos estatísticos apropriados para realizar o processo de seleção de bandas, tais como: Distância de *Battacharyya*, Divergência e Distância de *Jeffries-Matusita*³¹.

A Distância de *Battacharyya* permite determinar a separabilidade entre pares de classes. Assim, para cada conjunto de N bandas, determina-se a Distância de *Battacharyya* (índice de separabilidade), para os $K(K-1)/2$ pares possíveis de classes ($B_{12}, B_{13}, B_{14}...B_{46}, B_{N-1} N$, sendo K o número de classes consideradas), conforme a expressão que segue (JENSEN, 1986):

$$B_{12} = \frac{1}{8} (m_1 - m_2)^T [(K_1 + K_2)/2]^{-1} (m_1 - m_2) + \frac{1}{2} \ln \left(\frac{|(K_1 + K_2)/2|}{|K_1|^{1/2} |K_2|^{1/2}} \right) \quad [2.45]$$

onde:

m_1 é o vetor média da classe 1 para N bandas

m_2 é o vetor média da classe 2 para N bandas

K_1 é a matriz covariância da classe 1 para N bandas

K_2 é a matriz covariância da classe 2 para N bandas

O vetor média e a matriz de covariância, para ambas as classes, são calculados a partir de um conjunto de amostras de treinamento representativo, da área de estudo, previamente coletado³².

Após, calcula-se a média dos índices de separabilidade obtidos pelos pares de classes, para cada conjunto de bandas. Em seguida, seleciona-se o(s) conjunto(s) de bandas que apresenta(m) o(s) maior(es) valor(es) de separabilidade média, pois este(s) separa(m) melhor todas as classes, em geral.

³¹ Maiores informações sobre os métodos da Divergência e de *Jeffries-Matusita* podem ser adquiridas em SWAIN & DAVIS (1978).

³² Consultar seção 2.1 para obter maiores informações sobre a importância do conjunto de amostras de treinamento.

TABELA III - Bandas do *LANDSAT 5-TM* e suas aplicações.
 Fonte: JENSEN (1986)

BANDA	USO INDICADO PARA
1 (azul) 0.45 - 0.52 μm	Esta banda é útil para a análise do uso da terra, do solo e das características da vegetação. Os comprimentos de onda abaixo de 0.45 μm não são capturados pelo sensor pois são, consideravelmente, influenciados pela absorção e espalhamento da atmosfera.
2 (verde) 0.52 - 0.60 μm	Esta banda cobre a região entre as bandas de absorção da clorofila (azul e vermelho) e, assim, é indicada para a medição da vegetação verde sadia.
3 (vermelho) 0.63 - 0.69 μm	Esta é a banda vermelha de absorção da clorofila da vegetação verde sadia e representa uma das bandas mais importantes para a discriminação da vegetação. Pode exibir mais contraste do que as bandas 1 e 2 por causa do efeito reduzido da atenuação atmosférica.
4 (infravermelho próximo) 0.76 - 0.90 μm	Esta banda é especialmente indicada para determinar a quantidade de biomassa da vegetação presente na cena. Também é útil para a identificação de colheitas, além de acentuar os contrastes entre solo-colheita e terra-água.
5 (infravermelho médio) 1.55 - 1.75 μm	Esta banda é sensível à umidade de água nas plantas. Tal informação é útil no estudo de colheitas secas e nas investigações sobre o vigor das plantas. É uma das poucas bandas que pode ser usada para discriminar entre nuvens, neve e gelo, importante para a pesquisa hidrológica.
6 (infravermelho termal) 10.4 - 12.5 μm	Esta banda mede a quantidade de fluxo infravermelho radiante emitido pela superfície terrestre. É útil na localização da atividade geotermal, mapeamento da inércia termal para investigações geológicas, classificação e análise do <i>stress</i> da vegetação e estudo de misturas do solo.
7 (infravermelho médio) 2.08 - 2.35 μm	Esta é uma banda importante para a discriminação de formações rochosas. Também tem se mostrado útil na identificação de zonas de alteração hidrotermal em rochas.

Por fim, duas considerações são importantes, devendo ser consideradas no processo de classificação de imagens multi-espectrais do satélite *LANDSAT 5-TM*:

- A banda um é a que recebe maior interferência atmosférica, tendo os valores dos seus *pixels* mais alterados;
- A banda seis possui resolução espacial de 120 m, diferindo das demais que é de 30 m³³.

³³ Maiores informações sobre o Sistema *LANDSAT* podem ser obtidas no Anexo 03.

3. ÁREA DE ESTUDO

3.1 Localização e descrição

A área de estudo localiza-se próxima aos municípios de General Câmara, Santo Amaro e Taquari, no estado do Rio Grande do Sul, Brasil (Figura 3.1).

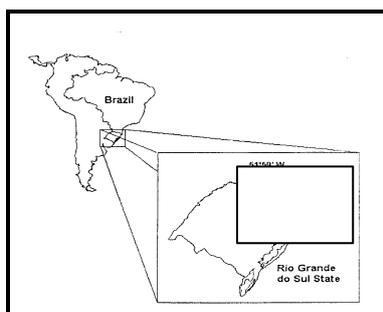


FIGURA 3.1 - Localização da área de estudo. Adaptação: DEPPE (1995)

A área possui 10.2 x 10.2 Km e pode ser geograficamente localizada na carta topográfica de Taquari (SH.22-V-D-V-3, MI-2969/3), nas seguintes coordenadas UTM: (411.390 - 6695.110) e (421.590 - 6684.910). A extensão (tamanho) da área foi definida em função da resolução espacial do satélite *LANDSAT 5-TM* que é de 30 m³⁴.

A Figura 3.2 mostra a imagem do satélite *LANDSAT 5-TM* (340 x 340 *pixels*) que cobre esta área. A imagem é a de órbita 221/81, do quadrante A, de novembro de 1994 e pertence à Empresa Riocell.

Segundo o Inventário Florestal Nacional do Instituto Brasileiro de Desenvolvimento Florestal (IBDF, 1983), a área de estudo situa-se na Micro-Região número 315 (ver Anexo 05) que está inserida na Região Fisiográfica denominada Depressão Central (ver Anexo 04). Esta região apresenta as seguintes características (IBDF, 1983):

- Relevo levemente ondulado;
- Altitudes inferiores a 100 m (exceto nos tabuleiros onde a altitude máxima é de 250 a 300 m);
- Precipitações em torno de 1.600 mm;

³⁴ Maiores informações sobre resolução espacial podem ser obtidas no Anexo 02. Consultar o Anexo 06 para visualizar a área de estudo em relação à capital metropolitana.

- Presença da bacia do Jacuí e seus afluentes;
- Vegetação do tipo: campestre, mata substituída pela agricultura e plantações de *Acácia* e *Eucalyptus*, e outras espécies como: Silvática e Palustre;
- Clima temperado, com temperatura superior a 22°C no mês mais quente e superior a 3°C no mês mais frio;
- É a região mais quente do estado, possuindo ventos pouco frequentes e de curta duração (ventos do norte e ventos do leste³⁵).

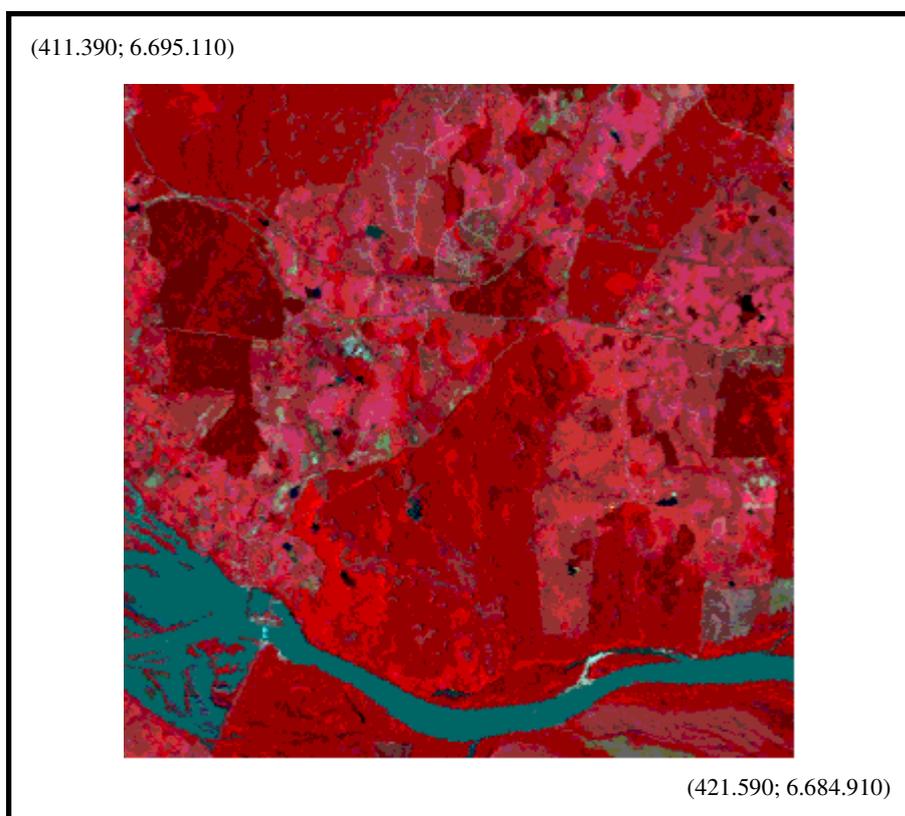


FIGURA 3.2 - Área de estudo. Composição colorida em RGB. Bandas 432

A Micro-Região³⁶ número 315 é constituída pelos municípios de: Arroio dos Ratos, Butiá, Cachoeira do Sul, General Câmara, Rio Pardo, São Jerônimo, Taquari e Triunfo. É a zona de maior importância na produção de arroz do estado do Rio Grande do Sul. Apresenta, ainda, uma significativa atividade pastoril e minas de carvão e

³⁵ Os ventos do leste são também conhecidos por ventos alísios. Sopram do oceano para o continente.

³⁶ O Estado do Rio Grande do Sul possui 24 Micro-Regiões caracterizadas pela sua forma de ocupação (IBDF, 1983).

calcário. Em termos de vegetação, é caracterizada por extensos reflorestamentos de *Acácia Negra* e *Eucalyptus*. A Tabela IV mostra a distribuição de áreas projetadas, por espécie, nesta Micro-Região.

TABELA IV - Distribuição de áreas por espécie na micro-região 315.
Fonte: IBDF (1983)

ESPÉCIES DE	DISTRIBUIÇÃO (hectares)
<i>Pinus</i>	2.010
<i>Eucalyptus</i>	3.215
<i>Araucária</i>	124
<i>Acácia</i>	19.515
Frutíferas	2.858
Nativas	433

Conforme o trabalho de campo realizado, somente algumas espécies de *Acácia*, *Eucalyptus* e Nativas predominam na área de estudo. Assim, apenas estas espécies foram selecionadas para o processo de classificação.

3.2 Espécies vegetais

Esta seção tem por finalidade relatar a origem, as características, o uso, as pragas florestais e a importância dos gêneros *Eucalyptus* e *Acácia* e de algumas espécies Nativas encontradas na área de estudo. As informações aqui contidas que referem-se ao gênero *Eucalyptus* foram extraídas de SOCIEDADE BRASILEIRA DE SILVICULTURA (1995a e 1995b), LAMPRECHT (1990) e CAMARGO (1975). As informações relacionadas ao gênero *Acácia* foram obtidas de LAMPRECHT (1990), EMBRAPA-CNPQ (1988) e MATTOS (1980). Por fim, as informações sobre as espécies nativas foram extraídas de REITZ et al. (1988) e IBDF (1983).

3.2.1 *Eucalyptus*

3.2.1.1 Origem

Este gênero, originário da Austrália, é o mais utilizado para fins de reflorestamento no país. As primeiras mudas foram trazidas para o Brasil, em 1825, com finalidades únicas de ornamentação e aproveitamento de suas características terapêuticas.

3.2.1.2 Características

O *Eucalyptus* se desenvolve bem em regiões elevadas das zonas tropicais e subtropicais, em solos próximos a lençóis de água subterrânea. Pode atingir poucos metros ou crescer até 100 metros de altura, dependendo da espécie e da fertilidade do solo. Possui grande resistência e capacidade de regeneração, mesmo depois de queimadas.

É de rápido crescimento e de elevada produção, desenvolvendo rapidamente uma grande superfície foliar. Suas folhas aprumam-se paralelamente aos feixes de luz, de maneira que as florestas de *Eucalyptus* deixam passar grande luminosidade e, conseqüentemente, protegem pouco o solo.

Possui raízes profundas e é um grande consumidor de água, sendo indicado para a drenagem de terrenos alagados. Porém, em lugares secos ele pode tornar-se concorrente com culturas agrícolas na absorção da água do solo.

Por fim, o *Eucalyptus* não tolera sombra, não podendo concorrer com outras espécies em solos férteis. Já em substratos mais pobres, ele ocupa posição dominante.

3.2.1.3 Espécies

Existem cerca de 600 espécies do gênero *Eucalyptus*.

O *Eucalyptus* se adapta bem em regiões com precipitações anuais variadas entre 250 e 1.700 mm, podendo ser cultivado desde o Norte até o Sul do país. Algumas espécies que melhor se adaptam às condições ecológicas do centro-sul do Brasil (com precipitação média em torno de 1.000 a 1.500 mm/ano) são: *Eucalyptus saligna*, *E. grandis*, *E. tereticornis* e *E. alba*. Outras espécies como *E. microcarpa*, *E. macrorrhyncha* e *E. marginata* são mais resistentes à seca e conseguem prosperar em áreas com precipitações entre 300 e 1.000 mm/ano.

Já as espécies *E. microtheca* e *E. coolabah* são capazes de prosperar em áreas bem mais áridas com apenas 270 mm/ano de precipitação pluvial.

3.2.1.4 Uso

Atualmente, existem cerca de 6,5 milhões de hectares de *Eucalyptus* plantados no país, e utilizados para os mais diversos fins, como: produção de tábuas, vigas, lâminas, postes telefônicos, moirões, chapas de fibra, carvão, lenha, móveis, cabos de ferramentas, portas, armações, matéria-prima para celulose, óleos essenciais para produtos de higiene, de perfumaria e medicamentos - antisséptico das vias respiratórias, expectorante, antifebril, pastilhas para tosse e outros.

Algumas espécies como *E. tereticornis*³⁷, *E. camaldulensis*³⁸ e *E. globulus*³⁹, que possuem madeira dura, compacta e durável, são altamente resistentes ao fogo e ao cupim. Estas espécies são adequadas para construções subterrâneas, hidráulicas, portuárias, para a construção de pontes, de barcos, de vagões, de estaleiros, para construções à prova de fogo, como escoras de minas e até mesmo para fins energéticos.

3.2.1.5 Pragas florestais

As espécies que possuem madeira mais flexível não são muito resistentes a determinadas pragas florestais, como cupins.

O *E. grandis* é, constantemente, atacado pelo fungo *Diaporthe Cubensis* que vai “minando a árvore como se fosse um câncer”.

O fungo *Cylindrocladium sp.* ataca as folhas do *E. alba* deixando-as doente e provocando a redução de seu crescimento.

Já no *E. saligna* encontra-se, muitas vezes, formigas cortadeiras.

³⁷ O *E. tereticornis* possui uma longevidade superior a 50 anos.

³⁸ O *E. camaldulensis* é considerado uma das madeiras de maior durabilidade do mundo. É adequado para reflorestamentos em regiões áridas e semi-áridas devido a sua elevada resistência à seca (LAMPRECHT, 1990).

³⁹ O *E. globulus* habita zonas moderadamente quentes e úmidas, não suportando longos períodos de seca (LAMPRECHT, 1990).

3.2.1.6 Importância

A importância e grande utilização do gênero *Eucalyptus* se deve, em primeiro lugar, à facilidade de adaptação desta espécie aqui no país. Isto se explica, pois há similaridade na posição do Brasil e da Austrália no globo terrestre. Logo, é de esperar que ambos os países possuam regiões ecologicamente semelhantes, e que o *Eucalyptus* se desenvolva tão bem aqui como ocorre na Austrália.

Em segundo lugar, o *Eucalyptus* gera riqueza na forma de impostos sendo utilizado na construção de estradas, hospitais, escolas e gera 550 mil empregos diretos, participando com 10% das divisas que entram no país, com a exportação de aço, ferro, celulose, chapas e outros produtos industriais. O Brasil é um tradicional exportador de produtos de *Eucalyptus*.

Em terceiro lugar, o *Eucalyptus* protege o solo da erosão, substitui a mata nativa (em seus usos econômicos - produz madeira e carvão), dá sombra e abrigo a aves e mamíferos, além de proteger a flora e a fauna.

Por fim, a cultura e o manejo do *Eucalyptus* é muito simples, o que explica o seu vasto uso no reflorestamento de várias partes do mundo⁴⁰.

3.2.2 Acácia

3.2.2.1 Origem

O gênero *Acácia* é nativo dos trópicos, tanto da Europa e África quanto da América e, assim como o *Eucalyptus*, a metade de suas espécies existentes no Brasil vieram da Austrália.

3.2.2.2 Características

A *Acácia* habita áreas tropicais e subtropicais, entre 30°N e 40°S. É recomendada para o plantio comercial em locais com temperatura média anual superior a 16°C, não sendo, em geral, resistente ao inverno.

Alcança cerca de 20 a 30 metros de altura e possui belas flores em coloração amarelo-ouro e amarelo-claro.

⁴⁰ Maiores informações sobre a Eucaliptocultura podem ser encontradas em SAMPAIO (1975) e GOLFARI (1975).

3.2.2.3 Espécies

Existem cerca de 700 a 800 espécies de *Acácia*.

Algumas espécies, tais como *A. albida* e *A. nilotica*, suportam períodos secos prolongados, existentes em regiões semidesérticas e áridas da África, e apresentam espinhos vistosos e fortes (*A. albida*).

Dentre as espécies existentes aqui no Brasil, a *Acácia Negra* é a mais utilizada para fins de reflorestamento. Alguns autores identificam três tipos distintos de *Acácia Negra* que são: *A. mearnsii* De Wild, *A. decurrens* (Wendl.) Wild e *A. dealbata* Link. Destas, a *A. mearnsii* é a predominante nos cultivos do Rio Grande do Sul. Esta espécie se adapta a terrenos degradados desde que bem drenados. Ela pode crescer vigorosamente em solos decapitados e tem apresentado bom desempenho em terrenos recompostos. Daí seu uso indicado para o reflorestamento.

A *A. dealbata* é raríssima no estado do Rio Grande do Sul e a *A. decurrens* apresenta uma casca mais pobre, para a extração de tanino, do que a *A. mearnsii*.

3.2.2.4 Uso

A *Acácia* é utilizada para a produção de lenha, carvão vegetal, forragens, palanques, como matéria-prima de grande qualidade na fabricação de celulose, papel, colas fenólicas e agentes anti-corrosivos, como ornamento com o uso de suas flores, como quebra-vento, como sombreadoras em regiões desérticas e de sua casca é extraído o tanino utilizado no curtimento de couros e peles.

As cinzas da madeira da *A. albida* é utilizada na fabricação de sabão e as suas flores e frutos são usados como alimento para animais, como abelhas e gado.

Já as sementes torradas da *A. nilotica*, encontrada na África, são usadas como tempero e suas vagens (frutos) podem ser utilizadas como legumes na nutrição humana.

3.2.2.5 Pragas florestais

A gomose e o serrador são dois fatores que comprometem a produtividade da *Acácia*.

A gomose é a exsudação (transpiração) através da casca, raízes e troncos ou galhos que aumenta com a idade do povoamento.

Já o serrador (*Oncideres impluviata*) é um besouro que corta os galhos e o tronco principal para a oviposição. O controle cultural deste inseto consiste em juntar os galhos cortados por ele, amontoá-los e queimá-los de fevereiro até fins de junho.

3.2.2.6 Importância

A *Acácia Negra* é uma das mais importantes espécies florestais do Rio Grande do Sul, sendo plantada em cerca de 30 municípios da Depressão Central.

Assim como o *Eucalyptus*, a *Acácia* é de fácil cultura e manejo, é de muitos usos e de boa produção (produtividade média de 20 st/ha.ano, em rotação de sete anos).

3.2.3 Nativas

3.2.3.1 Características

A vegetação nativa é o conjunto de espécies que melhor se adaptam ao ambiente local, que melhor servem à preservação do ambiente microbiológico do solo, ambiente este que é importante no desenvolvimento da fauna e da vegetação. Entretanto, as espécies nativas possuem um crescimento mais lento do que as exóticas (*Eucalyptus* e *Acácia*).

3.2.3.2 Espécies

A Região Depressão Central é caracterizada, em termos de vegetação, pela presença de avencas, gramíneas, arbustos, ervas (como a cressiuma - *chusquea sp*) e por árvores das espécies incluídas na Tabela V.

TABELA V - Principais espécies nativas encontradas na região Depressão Central.
 Fonte: REITZ (1988)

NOME POPULAR	NOME CIENTÍFICO
Açoita-cavalo	<i>Luhea divaricata</i>
Angico	<i>Parapiptadenia rigida</i>
Batinga	<i>Eugenia rostrifolia</i>
Cabriúva	<i>Myrocarpus frondosus</i>
Camboatá	<i>Matayba elaeagnoides</i>
Camboatá-vermelho	<i>Cupania vernalis</i>
Canela-garuva	<i>Nectandra rigida</i>
Canela-guaicá	<i>Ocotea puberula</i>
Canela-imbuia	<i>Nectandra megapotamica</i>
Canjerana	<i>Cabrlea canjerana</i>
Cedro	<i>Cedrela fissilis</i>
Cincho	<i>Sorocea bomplandii</i>
Grápia	<i>Apuleia leiocarpa</i>
Guajuvira	<i>Patagonula americana</i>
Ingá-feijão	<i>Inga marginata</i>
Laranjeira-do-mato	<i>Actinostemon concolor</i>
Louro	<i>Cordia trichotoma</i>
Mamica-de-cadela	<i>Fagara sp</i>
Salseiro	<i>Salix humboldtiana</i>
Sapopema	<i>Sloanea sp</i>
Tajuva	<i>Chlorophora tinctoria</i>
Tarumã	<i>Vitex megapotamica</i>
Timbaúva	<i>Enterolobium contortisiliquum</i>
Umbu	<i>Phytolacca dioica</i>
Urtigão	<i>Urera baccifera</i>

Existem muitas outras espécies vegetais nativas na Região Depressão Central. Entretanto, nesta pesquisa foram citadas, apenas, as mais relevantes⁴¹.

3.2.3.3 Uso

Em geral, as árvores nativas são utilizadas para a confecção de móveis, caixas, embalagens, ripas, fôrmas de sapatos e de outras peças torneadas, palitos de fósforo, instrumentos musicais, assoalhos, vigas, dormentes, moirões, estacas, postes, cabos de ferramentas, remos, na construção civil e naval, como lenha e carvão vegetal, na fabricação de celulose e papel, para extração de tanino e na arborização de ruas e praças.

Algumas espécies, como a *Cordia trichotoma* (Louro), a *Cabrlea canjerana* (Canjerana), a *Apuleia leiocarpa* (Grápia), a *Patagonula americana* (Guajuvira), a *Enterolobium contortisiliquum* (Timbaúva), a *Paraptadenia rigida* (Angico-vermelho) e a *Cedrela fissilis* (Cedro), são indicadas para reflorestamentos devido à utilidade, facilidade de cultivo e rápido crescimento e desenvolvimento.

Outras espécies, como a *Luhea divaricata* (Açoita-cavalo), a *Myrocarpus frondosus* (Cabriúva), a *Cabrlea canjerana* (Canjerana) e a *Salix humboldtiana* (Salseiro), são utilizadas, respectivamente, na fabricação de xarope, como incenso, na perfumaria e como chá para desagregar e expulsar cálculos renais.

3.2.3.4 Pragas florestais

As mudas da espécie *Parapiptadenia rigida* (Angico) são frequentemente amolestadas por fungos. Estes atacam o colo da planta levando-a à morte. A praga manifesta-se por pequenas manchas que aumentam abundantemente.

A espécie *Cedrela fissilis* (Cedro) é atacada pela larva *Hypsipyla grandella* Zell., mariposa da família *Phycitidae*. Esta larva ataca os brotos terminais da planta tornando impraticável o reflorestamento em grande escala.

Já o fungo *Batryconis pallida* ataca os frutos da espécie *Ocotea puberula* (Canela-guaicá), diminuindo a produção de sementes férteis.

3.2.3.5 Considerações

⁴¹ Consultar REITZ et al. (1988) para obter mais detalhes do tipo: família, características, potencialidades, morfologia, fenologia, uso e outros, sobre as espécies nativas aqui citadas.

Com a vinda de italianos (1824), para a região da serra, e dos alemães (1874), para a região do Rio dos Sinos, iniciou-se uma grande devastação das espécies vegetais nativas existentes no Rio Grande do Sul. Muitas árvores foram derrubadas para dar lugar a plantações de trigo e soja e, até mesmo, para a construção de casas e móveis. Assim, as áreas onde, antes, havia florestas nativas foram ocupadas pela agricultura ou reflorestadas com espécies exóticas.

Ainda hoje, a preferência pelo reflorestamento com espécies exóticas, e não com as próprias espécies naturais, se deve, pelo menos, por dois motivos:

- Pouco conhecimento do comportamento, ecologia, dinamismo, exigências ambientais e métodos silviculturais para cada espécie natural. Já os métodos silviculturais das espécies exóticas são bastante divulgados, garantindo o sucesso com as plantações destas espécies e;
- É mais interessante, economicamente, reflorestar com espécies exóticas que possuem um crescimento mais rápido, gerando uma maior produção.

3.3 Descrição das classes

Além das espécies vegetais nativas e exóticas (espécies de *Eucalyptus* e *Acácia*), é possível encontrar, na área de estudo, áreas de pastagem e de solo exposto e corpos d'água. Desta forma, esta seção tem por finalidade descrever, ou caracterizar, cada uma destas classes.

3.3.1 Nativa

Pertence a esta classe desde arbustos até árvores de baixa e alta estatura (20 a 25 metros), sendo que as árvores mais altas são raramente presentes.

As florestas nativas aparecem ao longo de drenagens ou em formações isoladas, já tendo sido bastante exploradas.

O nome popular e científico das principais espécies nativas encontradas, na área de estudo, aparecem na seção 3.2.3.2.

3.3.2 *Eucalyptus*

Esta classe inclui as florestas artificiais de *Eucalyptus*, cujo plantio foi planejado e realizado em grandes extensões homogêneas.

Grande parte aparece no reflorestamento de Santo Amaro, pertencente à Empresa Riocell, que utiliza esta madeira para a produção de papel e celulose.

Encontra-se *Eucalyptus* menores e maiores de três anos, plantados com um espaçamento entre 2 metros x 2 metros e 2 metros x 3 metros. Este espaçamento diminui com o crescimento desta vegetação. Há *Eucalyptus* em situação de plantio (1 a 10 anos) e em situação de brotação (10 a 17 anos) que já passaram pelo primeiro corte.

As espécies plantadas pela Riocell são: *E. saligna*, *E. grandis*, *E. tereticornis* e *E. urophila*, sendo que algumas áreas estão plantadas com *Eucalyptus* que não chegaram a se desenvolver adequadamente.

3.3.3 *Acácia*

Similarmente à classe *Eucalyptus*, esta classe inclui as florestas artificiais de *Acácia mearsii*, aparecendo em áreas homogêneas, um pouco menores do que as áreas reflorestadas com *Eucalyptus*.

É possível encontrar árvores desta espécie, com idade inferior e superior a três anos, plantadas com um espaçamento que varia entre 2 metros x 2 metros e 2 metros x 3 metros.

No reflorestamento de Santo Amaro, grande parte do plantio de *Acácia* foi substituído pelas espécies de *Eucalyptus*.

3.3.4 Pastagem

Esta classe inclui gramíneas, leguminosas e mirtáceas, entre outras. É caracterizada pela presença de vegetação rasteira usada como pasto para o gado.

Não foi realizada distinção entre pastagem saudável (verde), úmida ou seca.

Além disto, esta classe aparece distribuída, em grande quantidade, na área de estudo.

3.3.5 Solo Exposto

Pertence a esta classe as regiões com muito pouco ou nenhuma cobertura vegetal. Os solos arados estão aqui incluídos.

3.3.6 Água

Esta classe inclui os corpos d'água, como: o rio Jacuí (que atravessa a área de estudo de oeste a leste) e os reservatórios naturais e/ou os construídos pelo homem.

3.3.7 Desconhecida

Esta classe inclui todos os alvos cuja probabilidade de pertencer a qualquer outra classe, acima citada, seja muito pequena (menor ou igual a 1%).

As estradas e caminhos, que permitem o acesso à região, devem ser atribuídos a esta classe.

4. MATERIAIS UTILIZADOS

A correção geométrica, a *clusterização* pelo método tradicional, a coleta de amostras, a seleção de bandas e a classificação pelo método de Máxima Verossimilhança Gaussiana foram realizadas com o uso dos seguintes recursos de *hardware* e *software*:

- PC *Pentium*, 166 Mhz, 32 MB de RAM, monitor SVGA colorido (1024 x 768), disco flexível 3 1/2" e 2.0 GB de disco rígido;
- Sistema Operacional *Windows 95*;
- *Software* IDRISI - Sistema de Processamento e Tratamento de Imagens integrado a um Sistema de Informações Geográficas⁴², desenvolvido por *The Graduate School of Geography at Clark University*. Versão 1.01.002 *for Windows*;
- *Microsoft Excel 7.0* (utilizado na seleção de bandas pela Distância de *Battacharyya* e para a criação de gráficos).

A Rede Neural Multinível com *BackPropagation* e os demais programas que permitiram a análise estatística dos resultados obtidos (ver Anexos de 11 a 13) foram implementados utilizando-se os seguintes recursos:

- PC *Pentium* (como acima);
- Sistema Operacional *Windows 95*;
- Compilador C padrão.

A *clusterização* da área de estudo por *Kohonen* foi realizada no Sistema IRENE (Implementação de Redes Neurais), desenvolvido por NUNES (1995), em linguagem de programação C padrão e plataforma *SUN* (Sistema Operacional *Unix*).

Por sua vez, o trabalho de campo fez uso dos seguintes equipamentos e documentos:

Equipamentos:

⁴² Sistema de Informações Geográficas (SIG) é um sistema que serve para a entrada, armazenamento, recuperação, análise e exposição de dados geográficos interpretados (EASTMAN, 1996). Através dele é possível a obtenção de mapas temáticos individuais ou sobrepostos (ex.: relevo em perspectiva com imagens de cobertura), de modo que um intérprete poderá analisar áreas através de imagens tridimensionais das mesmas.

- *GPS (Global Position System)* - Sistema de Posicionamento no Globo - *GPS* de Navegação;
- Máquina Fotográfica (35 mm, ASA 100).

Documentos:

- Cartas topográficas da DSG, de escala 1:50.000 da região - carta de Taquari (SH.22-V-D-V-3, MI-2969/3) e carta de São Jerônimo (SH.22-V-D-V-4, MI-2969/4);
- Fotos da Riocell, de escala 1:20.000 de parte da região (incluindo o reflorestamento Santo Amaro), de junho/91;
- Imagem de 76 x 43 Km, falsa cor, mostrando a trajetória Porto Alegre/Área de Estudo (ver Anexo 06);
- Imagem da Área de Estudo (10.2 x 10.2 Km), falsa cor (ver Anexo 07);
- Estradas digitalizadas;
- *Imagettes* e Formulários (ver Anexo 10).

Nota-se que, neste trabalho, as *Imagettes* são regiões de 2.1 x 2.1 Km (70 x 70 *pixels*) que foram extraídas da área de estudo e impressas em papel HP especial/brilhante, na escala de 1:10.000, falsa cor. O Anexo 10 mostra as doze *Imagettes* confeccionadas. A parte central da *Imagette* (1.02 x 1.02 Km ou 34 x 34 *pixels*), delimitada por um quadrado, equivale a uma determinada área amostral cujas classes foram devidamente mapeadas através de verificações em campo. A parte externa à região delimitada foi utilizada como um auxílio no mapeamento, pois contém, muitas vezes, informações de contexto das classes mapeadas.

Por fim, salienta-se que todas as etapas deste trabalho utilizaram, pelo menos, três das seis bandas (1, 2, 3, 4, 5 e 7) do satélite *LANDSAT 5-TM*. Estas bandas são do quadrante A, da órbita 221/81, de novembro de 1994 e pertencem a Riocell. A banda seis não foi utilizada por coletar a energia emitida pelos alvos da superfície terrestre, enquanto que as demais coletam a energia refletida. Além do que esta banda apresenta uma resolução espacial de 120 m diferindo das demais que é de 30 m.

5 METODOLOGIA

Este estudo pode ser descrito em, praticamente, cinco etapas: geo-referenciamento das imagens de satélite, aquisição de dados de campo, *clusterização* de parte da área de estudo pelo método do Histograma Tridimensional e por *Kohonen*, classificação de parte da área de estudo pelo método de Máxima Verossimilhança Gaussiana e pela Rede Neural Artificial Multinível com *BackPropagation*, e aplicação do método estatístico para análise dos resultados. A Figura 5.1 ilustra estas etapas e a ordem em que foram executadas.

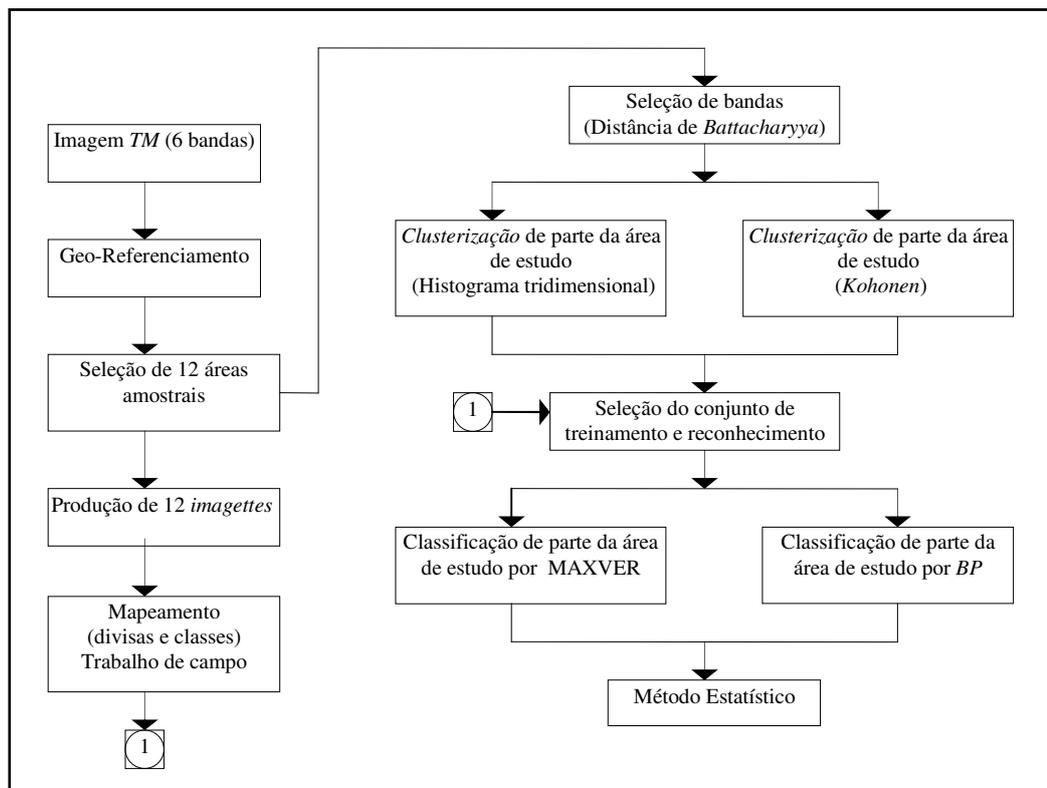


FIGURA 5.1 - Etapas e ordem de execução

5.1 Geo-referenciamento

A primeira etapa deste trabalho foi o geo-referenciamento das bandas 1, 2, 3, 4, 5 e 7, do satélite *LANDSAT 5-TM*, de novembro de 1994, que cobrem a área de estudo. Optou-se por geo-referenciar uma região maior do que a área de estudo, pois este processo gera uma imagem ligeiramente rotacionada para a direita (Figura 5.2). Após, para cada uma das bandas, extraiu-se a área de estudo da região geo-referenciada.

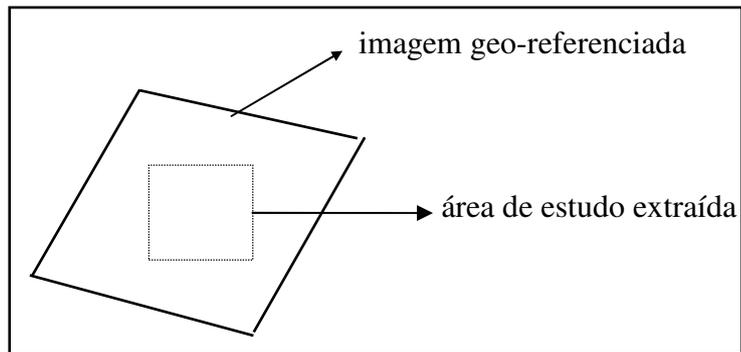


FIGURA 5.2 - Área de estudo geo-referenciada

O geo-referenciamento foi realizado com o uso do *software Idrisi for Windows* e pode ser descrito nos passos que seguem:

PASSO 1: COLETA DE ONZE PARES DE PONTOS DE CONTROLE

Procurou-se selecionar pontos bem distribuídos e bem definidos tanto na imagem de satélite quanto nas cartas topográficas. Para uma melhor identificação visual destes pontos, na imagem, utilizou-se, principalmente, a banda 3, visto que esta apresenta uma boa distinção entre água, vegetação e solo.

PASSO 2: MONTAGEM DO ARQUIVO DE CORRESPONDÊNCIA <PONTOS.COR> COM OS PONTOS COLETADOS

A Tabela VI mostra o conteúdo do arquivo de correspondência. A primeira linha especifica o número de pontos ou pares de coordenadas coletados, enquanto que as demais linhas mostram as coordenadas na imagem (X_i, Y_i) e as coordenadas no terreno (X_T, Y_T), nesta ordem.

TABELA VI - Pontos de controle obtidos

11	25040	60530	406425	6715550
	35895	60600	417150	6713825
	45165	15900	419200	6668250
	66000	48360	444900	6696900
	60585	19305	434925	6669125
	74475	16485	448175	6664125
	78810	70320	461050	6716550
	9270	42990	388075	6700775
	17600	61350	399250	6717525
	38140	89770	424075	6742225
	93670	46870	471975	6691000

PASSO 3: CÁLCULO DA EQUAÇÃO DE MELHOR AJUSTE ENTRE OS SISTEMAS DE COORDENADAS E CONVERSÃO DE CADA UMA DAS BANDAS PARA O SISTEMA UTM

A Figura 5.3 ilustra as informações fornecidas para o cálculo das equações de ajuste utilizadas na conversão das bandas para o novo sistema de referência.

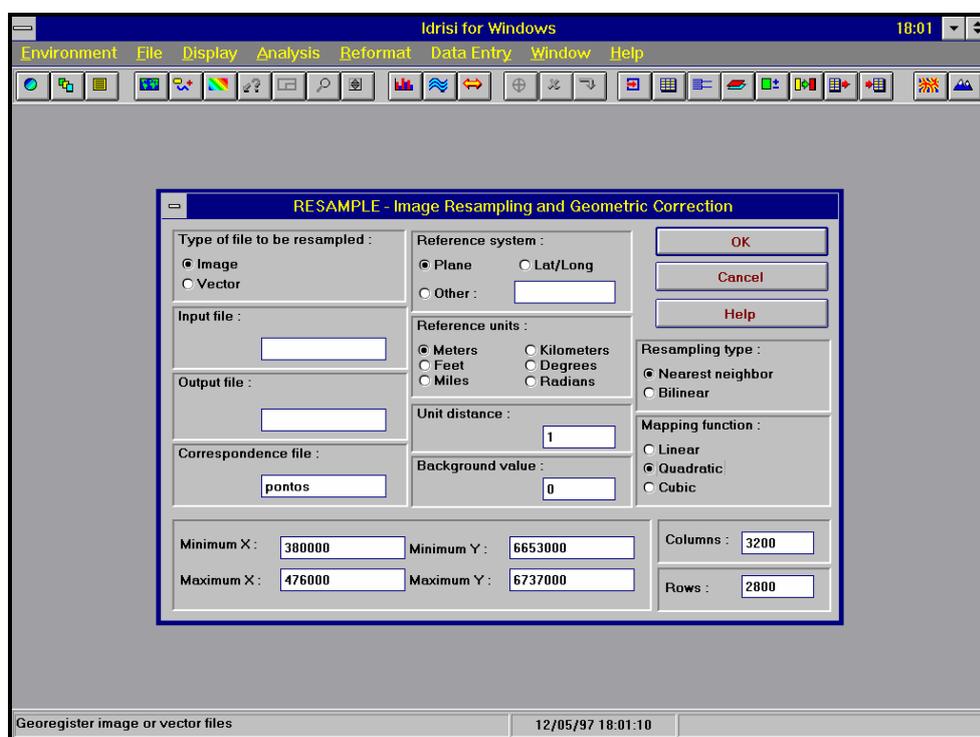


FIGURA 5.3 - Informações para o Geo-Referenciamento

O *software* Idrisi permite a escolha de uma das três funções de mapeamento: linear, quadrática ou cúbica. Entretanto, é preciso de, no mínimo, três pontos de controle para a função linear, seis para a quadrática e dez para a cúbica. Por sua vez, a resolução obtida na imagem geo-referenciada é resultado do número de linhas e colunas estabelecido (Figura 5.3).

PASSO 4: VERIFICAÇÃO DO ERRO MÉDIO QUADRADO

A etapa final do geo-referenciamento é a obtenção de informações sobre o erro médio gerado em função dos pontos de controle selecionados.

O erro médio quadrado obtido foi inferior a um *pixel*, o que é perfeitamente satisfatório.

Este procedimento foi realizado tanto para o tipo de amostragem Bilinear quanto para o Vizinho mais Próximo. As bandas geo-referenciadas com o tipo Bilinear foram utilizadas para fins de análise visual (confecção de *imagettes*). Já as bandas geo-referenciadas com amostragem do tipo Vizinho mais Próximo foram utilizadas nas *clusterizações* e classificações supervisionadas. Isto deve-se ao fato de que a amostragem Bilinear altera os valores dos contadores digitais para melhorar a aparência da imagem, enquanto que a amostragem do tipo Vizinho mais Próximo é a que mais preserva os valores originais dos contadores digitais. O Anexo 08 apresenta maiores detalhes sobre o geo-referenciamento.

5.2 Verificação de campo

A verificação de campo consistiu na identificação de alvos em doze áreas amostrais extraídas da área de estudo. Estas áreas, após averiguadas e mapeadas em campo, foram utilizadas para:

- A seleção de amostras de treinamento para os classificadores supervisionados;
- A seleção de amostras de reconhecimento que serviram na comparação entre o método de Máxima Verossimilhança Gaussiana e a Rede Neural Multinível com *BackPropagation*;
- A avaliação da *clusterização* obtida pelo método do Histograma Tridimensional e por *Kohonen*.

A verificação de campo será descrita nas próximas subseções.

5.2.1 Confeção de material

5.2.1.1 Imagettes

Primeiramente, a área de estudo (10.2 x 10.2 Km ou 340 x 340 *pixels*) foi sobreposta por uma grade retangular que a dividiu em 100 áreas de igual tamanho (1.02 x 1.02 Km ou 34 x 34 *pixels* - Figura 5.4).

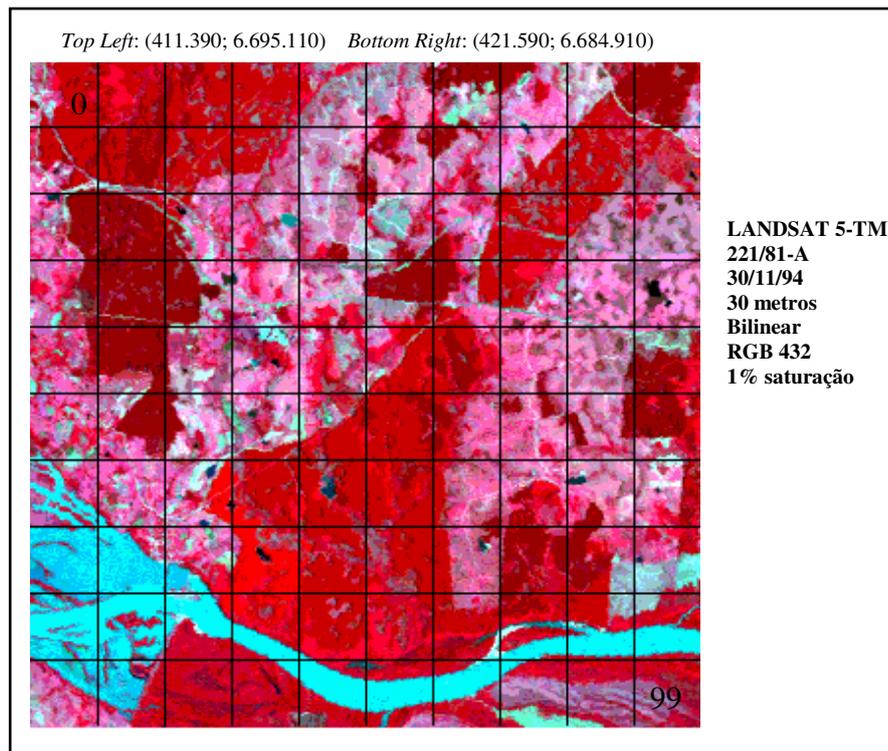


FIGURA 5.4 - Área de estudo dividida em áreas amostrais

Após, um programa que gera números aleatórios, entre 0 e 99, foi implementado, em linguagem de programação C padrão, (o código fonte é apresentado no Anexo 11). Este programa selecionou, aleatoriamente, as 12 áreas (12% da área de estudo) que podem ser observadas na Figura 5.5.

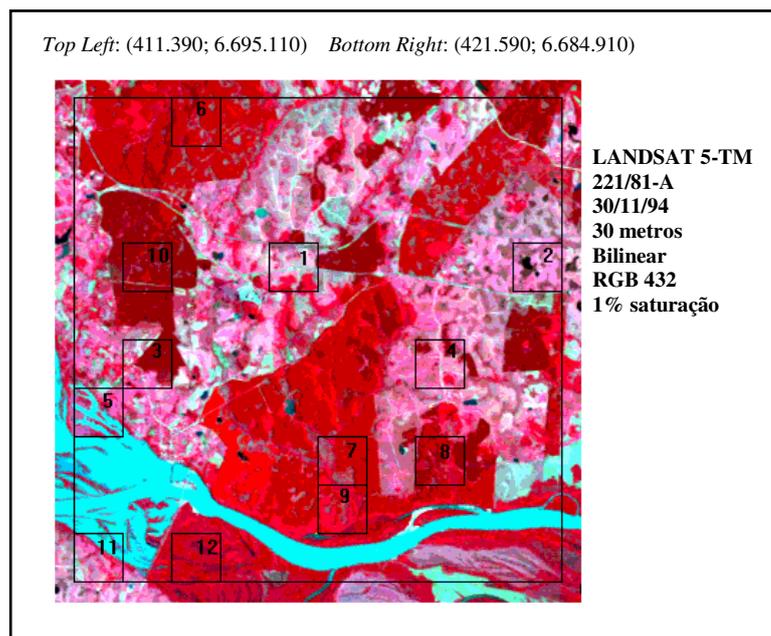


FIGURA 5.5 - Áreas amostrais selecionadas

Cada área amostral foi extraída da composição RGB Bilinear, bandas 432, da área de estudo e impressa em papel especial/brilhante (ver Anexo 10) para, posteriormente, ser mapeada em campo. Adotou-se esta metodologia visto que, em função do alto custo envolvido e do tempo disponível, não era possível mapear toda a área de estudo. Maiores informações sobre métodos estatísticos de extração de amostras podem ser obtidas em SPIEGEL (1978).

5.2.1.2 Formulários

A cada *imagette* acompanha um formulário que permite registrar as classes contidas nela e quaisquer outras informações que sejam relevantes (ver Anexo 10).

5.2.1.3 Tabela de classificação

A Tabela V mostra o código e a cor estabelecidos, arbitrariamente, para cada uma das possíveis classes a serem encontradas nas áreas amostrais.

Salienta-se que, neste trabalho, não foram incluídas subclasses para as classes adotadas, pois para isto seria necessário uma verificação de campo extremamente detalhada. Entretanto, isto se tornou inviável devido ao tempo disponível

e a defasagem entre a realização do trabalho de campo (dez/96 a fev/97), a época de aquisição da imagem (nov/94) e as fotos da área de estudo disponibilizadas pela Riocell (jun/91).

TABELA VII - Tabela de classificação adotada

CÓDIGO	CLASSE	COR	RGB
0	Desconhecida	Preto	0 0 0
1	Nativa	Vermelho	229 0 0
2	<i>Eucalyptus</i>	Amarelo	225 191 0
3	<i>Acácia</i>	Verde Escuro	45 162 38
4	Pastagem	Verde Claro	76 222 167
5	Solo Exposto	Azul Claro	0 125 221
6	Água	Azul Escuro	0 56 163

5.2.1.4 Estradas digitalizadas

As principais estradas e caminhos encontrados, na área de estudo, foram digitalizados para auxiliar no deslocamento entre as áreas amostrais (Figura 5.6). Esta digitalização foi realizada diretamente na tela, sobre a composição RGB Bilinear, bandas 432, da área de estudo. Para tanto, utilizou-se o *software* Idrisi for Windows versão 1.01.002.

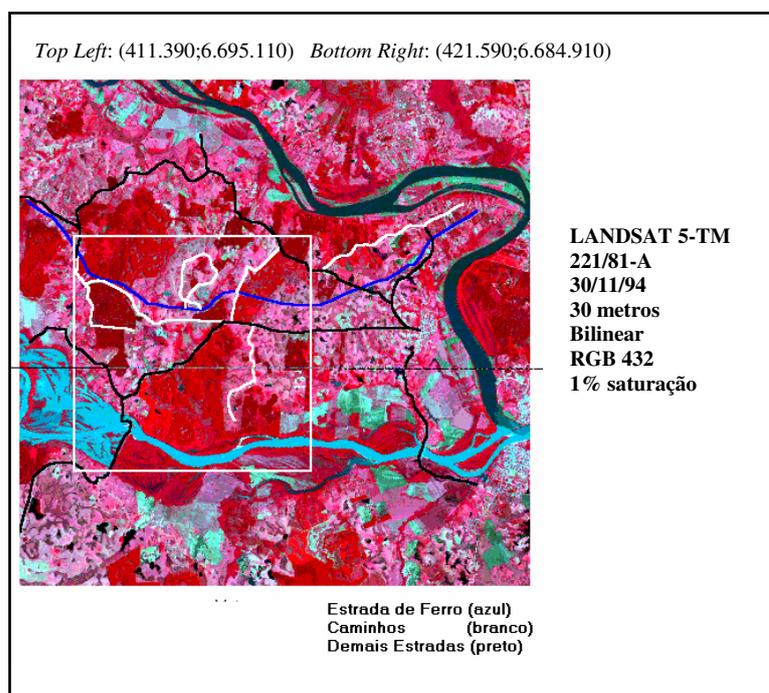


FIGURA 5.6 - Estradas e caminhos na área de estudo

5.2.1.5 Imagem Porto Alegre-área de estudo

Também, com a finalidade de auxiliar na localização da área de estudo, obteve-se uma imagem que mostra, claramente, a distância entre a área de estudo e a capital metropolitana (Porto Alegre). Consultar o Anexo 06 para visualizar esta imagem.

5.2.2 Estabelecimento do trajeto

Três dias foram necessários para o mapeamento das doze áreas amostrais. A Tabela VIII mostra, em ordem, as amostras verificadas a cada dia.

TABELA VIII - Distribuição de amostras/dia

DATA	AMOSTRAS
19/12/96	02, 01 e 10
17/01/97	06, 04, 08, 03 e 05
03/02/97	07, 09, 11 e 12

5.2.3 Mapeamento das *Imagettes*

As áreas amostrais foram localizadas com o auxílio do GPS (*Global Position System*), das cartas topográficas e do material confeccionado.

As classes identificadas foram mapeadas nas *imagettes* e algumas fotografias foram obtidas.

A maior dificuldade encontrada foi em relação às amostras 07 e 09, pois, além da vegetação ser muito densa e fechada, não havia acesso (estradas ou caminhos) disponível até estes locais. Assim, estas amostras foram identificadas com o auxílio da Riocell que disponibilizou a verificação de fotografias aéreas (de escala 1:20.000, de junho/91), mapas da região (datados de 1995) e anotações da época da aquisição da imagem. Estas informações foram possíveis, pois as amostras 07 e 09 estão situadas em um grande povoamento de *Eucalyptus* pertencente a esta empresa.

5.3 Seleção de bandas

Este procedimento foi necessário para determinar quais as bandas a serem utilizadas nas classificações supervisionadas e não-supervisionadas. Para tanto, utilizou-se a Distância de *Bhattacharyya* para determinar a separabilidade média entre as classes para todos os 63 possíveis conjuntos de seis bandas (1, 2, 3, 4, 5 e 7) do satélite *LANDSAT 5-TM*. O Anexo 14 mostra os valores de separabilidade obtidos, incluindo a separabilidade média. Nota-se que, para este estudo, foram selecionados os conjuntos de bandas que apresentaram os maiores valores de separabilidade média, pois estes separam melhor todas as classes, em geral.

Salienta-se que o conjunto de amostras utilizado para o cálculo da Distância de *Bhattacharyya* foi reaproveitado para o conjunto de treinamento dos classificadores supervisionados. A seção 5.5.1 descreve detalhadamente como estas amostras foram coletadas.

5.4 Clusterização

A clusterização foi utilizada para a identificação das possíveis classes (e subclasses) existentes na área de estudo. Desta forma, as doze áreas amostrais⁴³ foram *clusterizadas* tanto pelo método do Histograma Tridimensional quanto por *Kohonen*. Este processo, juntamente com as informações verificadas a campo, auxiliou na obtenção de um conjunto de treinamento representativo da área de estudo, uma vez que as variações dentro de cada uma das classes (nativa, *eucalyptus*, *acácia*, pastagem, solo e água) puderam ser observadas.

5.4.1 Método tradicional

A *clusterização* pelo método do Histograma Tridimensional foi obtida através do *software* IDRISI. O primeiro passo deste processo foi a escolha de dois conjuntos de três bandas para a obtenção de duas composições RGB, visto que cada Histograma Tridimensional foi obtido sobre uma composição. A Tabela IX apresenta os

⁴³ Para cada uma das bandas foi montado um mosaico com as doze áreas amostrais.

testes realizados incluindo as bandas utilizadas em cada teste. Salienta-se que foi realizada a abordagem fina e os *clusters* menos significativos foram excluídos⁴⁴.

TABELA IX - *Clusterizações* pelo método do Histograma Tridimensional

TESTE	BANDAS (COMPOSIÇÃO RGB COM SATURAÇÃO DE 2.5)
01	345
02	347

Optou-se por dois testes, pois representam 10% das possibilidades (existem 20 possíveis conjuntos de três bandas). Além disto, utilizou-se os conjuntos de bandas 345 e 347, visto que, de todos os conjuntos de três bandas, estes foram os que apresentaram os maiores valores de separabilidade média (consultar Anexo 14).

As *clusterizações* obtidas pelo método do Histograma Tridimensional podem ser encontradas no capítulo 6.

5.4.2 Kohonen

A clusterização por *Kohonen* foi realizada através do *software* IRENE. Como este método não apresenta limitações quanto ao número de bandas que podem ser utilizadas, optou-se por realizar três testes, sendo que um deles utiliza as seis bandas⁴⁵. Considerava-se a hipótese de que quanto maior fosse o número de bandas, melhor seria a clusterização. A Tabela X apresenta os testes realizados e os parâmetros fornecidos para a clusterização, das áreas amostrais, por esta Rede Neural.

TABELA X - *Clusterizações* por *Kohonen*

TESTE	BANDAS	DIMENSÃO DO MAPA	ITERAÇÕES	SIGMA (VIZINHANÇA)	COEF. DE APRENDIZADO
01	345	3	150.000	2.0	0.01
02	23457	6	50.000	3.0	0.5
03	123457	6	50.000	3.0	0.5

⁴⁴ O *software* IDRISI permite a escolha entre uma abordagem ampla ou fina e, ainda, as opções de considerar todos os *clusters*, excluir os menos significativos ou determinar o número máximo de *clusters* a serem considerados.

⁴⁵ Para *Kohonen*, seria possível realizar 63 testes, uma vez que estes poderiam utilizar conjuntos de N bandas (sendo N=1...6). Dos vários testes realizados, os testes 02 e 03 apresentaram os melhores resultados. O teste 01, de *Kohonen*, foi mantido para ser comparado com o resultado do teste 01 do método do Histograma Tridimensional.

Nota-se que a vizinhança é contínua e que o mapa utilizado possui uma topologia cúbica. Desta maneira, cada posição do mapa (cubo) está associada a uma cor RGB. Logo, pressupõe-se que classes espectralmente próximas possuem cores semelhantes na imagem *clusterizada*.

A dimensão equivale ao número de neurônios por lado no cubo, ou seja, no primeiro teste, o mapa contém 27 neurônios dispostos em 3 x 3 x 3. Por fim, o sigma ideal é, em geral, cerca da metade da dimensão do mapa.

5.5 Classificação supervisionada

A coleta de amostras e a classificação de parte da área de estudo pelo método de Máxima Verossimilhança Gaussiana foram realizadas pelo *software* IDRISI. Já a classificação pela Rede Neural Multinível com *BackPropagation* foi realizada por um programa implementado para este fim (ver Anexo 12).

5.5.1 Coleta de Amostras

Para a obtenção dos resultados dos classificadores supervisionados (MAXVER e RNA), um conjunto de amostras de treinamento foi, cuidadosamente, selecionado sobre as áreas amostrais 02, 07, 10 e 11. Estas áreas foram escolhidas, pois continham amostras representativas de todas as classes (nativa, *eucalyptus*, *acácia*, pastagem, solo e água) utilizadas neste estudo. As demais áreas amostrais foram utilizadas para a aquisição do conjunto de reconhecimento utilizado na avaliação dos classificadores (ver seção 5.6). O Anexo 07 mostra as amostras coletadas, em áreas quase sempre retangulares, sobre uma composição RGB Bilinear, bandas 432.

Cerca de 0.9% do número de *pixels* da imagem, da área de estudo, foram selecionados para o conjunto de treinamento (Tabela XI). Numericamente, esta amostragem é satisfatória visto que o número de *pixels* para cada classe é maior do que a quantidade mínima exigida teoricamente (60 *pixels*/classe)⁴⁶. Esta seleção foi realizada com o auxílio do trabalho de campo e dos mosaicos *clusterizados*.

⁴⁶ EASTMAN (1996) afirma que o número de *pixels* para cada classe não deve ser menor do que dez vezes o número de bandas que estão sendo utilizadas.

TABELA XI - Conjunto de treinamento (número de *pixels*/classe)

CÓDIGO	CLASSE	Nº DE <i>PIXELS</i>	% ÁREA DE ESTUDO
1	Nativa	212	0.18
2	<i>Eucalyptus</i>	219	0.19
3	<i>Acácia</i>	212	0.18
4	Pastagem	212	0.18
5	Solo Exposto	69	0.06
6	Água	129	0.11
Conj. de Treinamento	Total	1053	0.90
Área de Estudo	Total	115600	

A Figura 5.7 permite uma análise qualitativa do conjunto de treinamento.

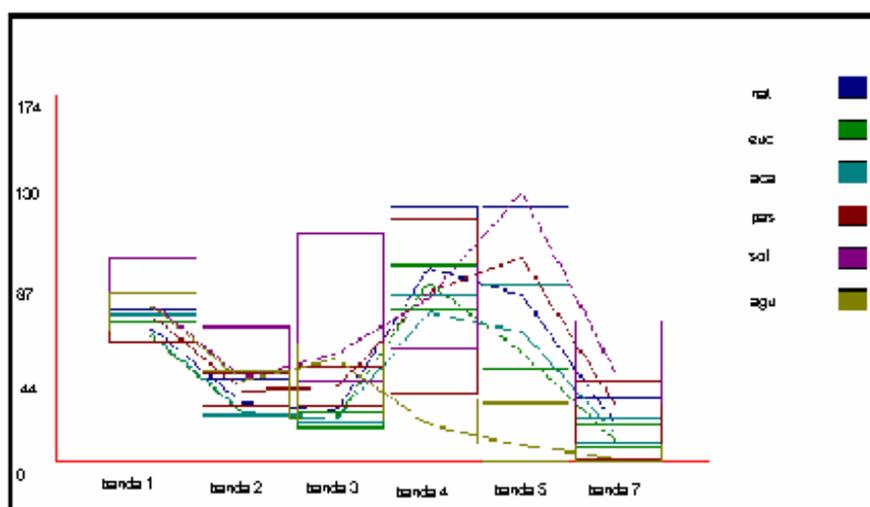


FIGURA 5.7 - Assinaturas espectrais das classes pré-definidas

O Anexo 09 mostra o histograma de cada classe, em cada uma das seis bandas, o que permite observar se as amostras apresentam ou não distribuição gaussiana.

5.5.2 Máxima Verossimilhança Gaussiana

Utilizando-se o conjunto de treinamento preestabelecido, foi possível classificar parte da área de estudo, pelo método de Máxima Verossimilhança Gaussiana. Os 6 conjuntos de bandas (cerca de 10% do número total) que apresentaram os maiores valores de separabilidade média foram selecionados como testes para os classificadores supervisionados, conforme mostra a Tabela XII⁴⁷.

TABELA XII - Classificações por MAXVER

TESTE	BANDAS
01	123457
02	12345
03	13457
04	12457
05	12347
06	23457

Em todas as classificações, definiu-se igual probabilidade de ocorrência das classes, visto que não se tinha conhecimento desta probabilidade “a priori”. Ou, em outras palavras, não foi possível obter informações sobre o quanto de *Eucalyptus*, *Acácia*, Nativa, Pastagem, Solo Exposto e Corpos d’água existia, de fato, na área de estudo, quando da aquisição da imagem (novembro de 1994).

Optou-se por excluir 1% dos *pixels*, o que parece aceitável, pois podem existir *pixels* que não pertençam a nenhuma das seis classes pré-definidas, por apresentarem valores muito baixos de $P(X/W_i)$, para todas as classes. Estes *pixels* foram atribuídos à classe denominada Desconhecida.

As classificações obtidas pelo método de Máxima Verossimilhança Gaussiana podem ser encontradas no capítulo 6.

⁴⁷ Para maiores informações consultar o Anexo 14.

5.5.3 Rede Neural Multinível com *BackPropagation*

A classificação da área de estudo, pela Rede Neural Multinível com *BackPropagation*, foi realizada com o uso do mesmo conjunto de treinamento utilizado pelo método de Máxima Verossimilhança Gaussiana. Isto permitiu que os resultados de ambos os métodos pudessem ser comparados posteriormente (ver capítulo 7).

A Tabela XIII mostra os parâmetros fornecidos à Rede Neural e o erro médio quadrado obtido em cada uma das classificações realizadas.

TABELA XIII - Classificações pela Rede Neural Multinível com *BackPropagation*

TESTE	BANDAS	Nº NEU. ENTR.	Nº NEU. INTERM.	Nº NEU. SAL.	ERRO MÉDIO QUADRADO
01	123457	6	10	6	0.031627
02	12345	5	10	6	0.082892
03	13457	5	10	6	0.056705
04	12457	5	10	6	0.089618
05	12347	5	10	6	0.080239
06	23457	5	10	6	0.054536

Nota-se que parte da área de estudo foi classificada com diferentes conjuntos de bandas, similarmente às classificações realizadas com o método de Máxima Verossimilhança Gaussiana.

O número de neurônios de entrada equivale ao número de bandas consideradas na classificação, visto que para cada neurônio de entrada é atribuído o valor de nível de cinza de cada *pixel*, do conjunto de treinamento, em cada banda.

O número de neurônios de saída é fixo em seis, pois considerou-se uma saída exclusiva e não binária para a rede. Assim, cada neurônio de saída representa uma das classes: *acácia*, *água*, *eucalyptus*, *nativa*, *pastagem* e *solo exposto*, respectivamente.

Durante a etapa de reconhecimento, cada *pixel* das áreas amostrais é fornecido à rede e aquele neurônio de saída cujo valor for maior ou igual a zero é o indicador da classe a qual o *pixel* pertence. A função de ativação utilizada é a tangente hiperbólica e, em função disto, as entradas foram normalizadas entre -1 e 1 e os pesos inicializados neste mesmo intervalo. Durante a fase de reconhecimento, a rede gera um

arquivo com a classe de cada um dos *pixels* do mosaico das áreas amostrais. Este arquivo pode ser visualizado no *software* IDRISI.

Utilizou-se, apenas, uma camada intermediária composta por 10 neurônios. O coeficiente de aprendizado e o número de iterações foram fixados em 0.01 e 50000, respectivamente, para todas as classificações.

Por fim, o algoritmo de *BackPropagation* implementado não utiliza a técnica do momento. A listagem do programa pode ser encontrado no Anexo 12.

5.6 Aplicação do método estatístico

A parte final deste trabalho visou estabelecer uma análise quantitativa da acurácia obtida pelos métodos supervisionados (Máxima Verossimilhança Gaussiana e Rede Neural Multinível com *BackPropagation*) utilizados na classificação de parte da área de estudo. Para tanto, a acurácia foi calculada para o conjunto de treinamento, a fim de verificar a capacidade dos classificadores em reconhecer os próprios *pixels* com os quais foram treinados, e para um conjunto de reconhecimento. 60 *pixels*/classe foram coletados para este conjunto com o auxílio das informações obtidas em campo. Neste caso, era de fundamental importância coletar pontos que não tivessem sido utilizados no treinamento e que pertencessem indubitavelmente a uma determinada classe escolhida.

A Tabela XIV mostra a quantidade de *pixels* por classe coletados para o conjunto de treinamento e de reconhecimento.

TABELA XIV - Quantidade de *pixels*/classe utilizados no conjunto de treinamento e de reconhecimento

CLASSE	CONJ. DE TREINAMENTO	CONJ. DE RECONHECIMENTO
Nativa	212	60
<i>Eucalyptus</i>	219	60
<i>Acácia</i>	212	60
Pastagem	212	60
Solo	69	60
Água	129	60
Total	1053	360

Cada ponto do conjunto de treinamento foi comparado com o seu respectivo ponto na imagem classificada pelo método de Máxima Verossimilhança Gaussiana. Isto foi realizado pelo programa ACURACIA.C implementado, em linguagem de programação C padrão, para este fim (o Anexo 13 apresenta a listagem do código fonte). Desta forma, o programa forneceu a quantidade de acertos e erros da classificação, além da distribuição do erro entre as classes. Este processo foi executado para todos os testes do método de Máxima Verossimilhança Gaussiana e da Rede Neural Multinível com *BackPropagation*.

Similarmente, cada ponto do conjunto de reconhecimento foi comparado com os resultados da classificação do método tradicional e da Rede Neural.

As Tabelas XV e XVI apresentam a porcentagem de acertos e a distribuição dos erros obtidos pelo método de Máxima Verossimilhança Gaussiana, para o conjunto de treinamento, para todos os seis testes realizados. As Tabelas XVII e XVIII apresentam as mesmas informações, porém para o conjunto de reconhecimento.

Já as Tabelas de XIX a XXII mostram a porcentagem de acertos e a distribuição dos erros obtidos pela Rede Neural, tanto para o conjunto de treinamento quanto para o de reconhecimento⁴⁸.

⁴⁸ O Anexo 15 contém estas mesmas tabelas (XV a XXII), porém quantificadas em *pixels*.

TABELA XV - Acertos obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de treinamento (em porcentagem)⁴⁹

	Total de Pontos	MAXVER1	MAXVER2	MAXVER3	MAXVER4	MAXVER5	MAXVER6
Nativa	212	90.09	77.36	85.85	84.43	83.02	88.68
<i>Eucalyptus</i>	219	95.89	95.89	95.43	96.89	95.89	96.80
<i>Acácia</i>	212	95.75	93.40	93.40	92.45	94.81	96.70
Pastagem	212	86.79	58.96	80.66	85.38	48.58	91.51
Solo	69	91.30	57.97	65.22	65.22	60.87	82.61
Água	129	91.47	89.92	82.17	81.40	88.37	90.70

TABELA XVI - Distribuição de erros obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de treinamento (em porcentagem)

MAXVER1	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	9.91	0.94	-----	0	7.55	1.42	0	0
<i>Eucalyptus</i>	4.11	0.46	1.83	-----	1.83	0	0	0
<i>Acácia</i>	4.25	1.89	2.36	0	-----	0	0	0
Pastagem	13.21	5.19	1.42	0	0	-----	6.60	0
Solo	8.70	5.80	0	0	0	2.90	-----	0
Água	8.53	8.53	0	0	0	0	0	-----
MAXVER2	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	22.64	4.25	-----	0.47	7.55	10.38	0	0
<i>Eucalyptus</i>	4.11	2.28	0	-----	1.83	0	0	0
<i>Acácia</i>	6.60	4.25	2.36	0	-----	0	0	0
Pastagem	41.04	32.08	0.47	0	0	-----	8.49	0
Solo	42.03	26.09	0	0	0	15.94	-----	0
Água	10.08	10.08	0	0	0	0	0	-----
MAXVER3	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	14.15	0.94	-----	0.47	7.55	5.19	0	0
<i>Eucalyptus</i>	4.57	0.46	0	-----	4.11	0	0	0
<i>Acácia</i>	6.60	1.42	5.19	0	-----	0	0	0
Pastagem	19.34	16.51	2.36	0	0	-----	0.47	0
Solo	34.78	17.39	0	0	0	17.39	-----	0
Água	17.83	17.83	0	0	0	0	0	-----
MAXVER4	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	15.57	3.77	-----	0	7.08	4.72	0	0
<i>Eucalyptus</i>	3.20	0.46	0.91	-----	1.83	0	0	0
<i>Acácia</i>	7.55	3.30	4.25	0	-----	0	0	0
Pastagem	14.62	10.85	1.89	0	0	-----	1.89	0
Solo	34.78	20.29	0	0	0	14.49	-----	0
Água	18.60	17.05	0	0	0	1.55	0	-----
MAXVER5	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	16.98	2.83	-----	0.47	7.08	6.60	0	0
<i>Eucalyptus</i>	4.11	2.28	0	-----	1.83	0	0	0
<i>Acácia</i>	5.19	2.83	1.89	0.47	-----	0	0	0
Pastagem	51.42	32.55	0.94	0	0	-----	17.92	0
Solo	39.13	28.99	0	0	0	10.14	-----	0
Água	11.63	11.63	0	0	0	0	0	-----
MAXVER6	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	11.32	1.42	-----	1.89	6.60	1.42	0	0
<i>Eucalyptus</i>	3.20	0.46	0.91	-----	1.83	0	0	0
<i>Acácia</i>	3.30	0.94	2.36	0	-----	0	0	0
Pastagem	8.49	5.66	0.94	0	0	-----	1.89	0
Solo	18.39	8.70	0	0	0	8.70	-----	0
Água	9.30	9.30	0	0	0	0	0	-----

⁴⁹ Os termos MAXVER1, MAXVER2...MAXVER6 se referem, respectivamente, aos testes 01, 02..06 realizados pelo Método de Máxima Verossimilhança Gaussiana conforme descrito na seção 5.5.2.

TABELA XVII - Acertos obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de reconhecimento (em porcentagem)

	Total de Pontos	MAXVER1	MAXVER2	MAXVER3	MAXVER4	MAXVER5	MAXVER6
Nativa	60	56.67	50.00	51.67	58.33	46.67	66.67
<i>Eucalyptus</i>	60	30.00	30.00	35.00	31.67	28.33	31.67
<i>Acácia</i>	60	48.33	50.00	51.67	46.67	48.33	56.67
Pastagem	60	66.67	55.00	65.00	63.33	40.00	66.67
Solo	60	43.33	46.67	33.33	38.33	65.00	43.33
Água	60	46.67	43.33	20.00	25.00	35.00	45.00

TABELA XVIII - Distribuição de erros obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de reconhecimento (em porcentagem)

MAXVER1	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	43.33	15.00	-----	5.00	15.00	8.33	0.00	0.00
<i>Eucalyptus</i>	70.00	13.33	46.67	-----	8.33	1.67	0.00	0.00
<i>Acácia</i>	51.67	3.33	38.33	1.67	-----	5.00	3.33	0.00
Pastagem	33.33	5.00	21.67	0.00	0.00	-----	6.67	0.00
Solo	56.67	26.67	0.00	0.00	0.00	30.00	-----	0.00
Água	53.33	40.00	0.00	0.00	0.00	11.67	1.67	-----
MAXVER2	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	50.00	20.00	-----	3.33	13.33	13.33	0.00	0.00
<i>Eucalyptus</i>	70.00	28.33	31.67	-----	8.33	1.67	0.00	0.00
<i>Acácia</i>	50.00	13.33	25.00	5.00	-----	6.67	0.00	0.00
Pastagem	45.00	26.67	10.00	0.00	1.67	-----	6.67	0.00
Solo	53.33	20.00	0.00	0.00	0.00	23.33	-----	0.00
Água	56.67	56.67	0.00	0.00	0.00	0.00	0.00	-----
MAXVER3	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	48.33	18.33	-----	5.00	13.33	11.67	0.00	0.00
<i>Eucalyptus</i>	65.00	13.33	41.67	-----	8.33	1.67	0.00	0.00
<i>Acácia</i>	48.33	11.67	30.00	5.00	-----	1.67	0.00	0.00
Pastagem	35.00	15.00	16.67	0.00	0.00	-----	3.33	0.00
Solo	66.67	26.67	0.00	0.00	0.00	40.00	-----	0.00
Água	80.00	73.33	0.00	0.00	0.00	5.00	1.67	-----
MAXVER4	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	41.67	16.67	-----	5.00	10.00	10.00	0.00	0.00
<i>Eucalyptus</i>	68.33	13.33	48.33	-----	6.67	0.00	0.00	0.00
<i>Acácia</i>	53.33	13.33	30.00	6.67	-----	3.33	0.00	0.00
Pastagem	36.67	8.33	21.67	0.00	1.67	-----	5.00	0.00
Solo	61.67	26.67	0.00	0.00	0.00	35.00	-----	0.00
Água	75.00	66.67	0.00	0.00	0.00	8.33	0.00	-----
MAXVER5	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	53.33	20.00	-----	5.00	15.00	13.33	0.00	0.00
<i>Eucalyptus</i>	71.67	28.33	30.00	-----	11.67	1.67	0.00	0.00
<i>Acácia</i>	51.67	15.00	25.00	6.67	-----	3.33	1.67	0.00
Pastagem	60.00	36.67	10.00	0.00	0.00	-----	13.33	0.00
Solo	35.00	30.00	0.00	0.00	0.00	5.00	-----	0.00
Água	65.00	65.00	0.00	0.00	0.00	0.00	0.00	-----
MAXVER6	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	33.33	3.33	-----	6.67	13.33	10.00	0.00	0.00
<i>Eucalyptus</i>	68.33	5.00	51.67	-----	11.67	0.00	0.00	0.00
<i>Acácia</i>	43.33	3.33	30.00	6.67	-----	3.33	0.00	0.00
Pastagem	33.33	3.33	20.00	0.00	1.67	-----	8.33	0.00
Solo	56.67	18.33	0.00	0.00	0.00	38.33	-----	0.00
Água	55.00	41.67	0.00	0.00	0.00	13.33	0.00	-----

TABELA XIX - Acertos obtidos pela Rede Neural Multinível com *BackPropagation* para o conjunto de treinamento (em porcentagem)⁵⁰

	Total de Pontos	RNA1	RNA2	RNA3	RNA4	RNA5	RNA6
Nativa	212	92.92	88.68	93.40	83.96	91.51	92.45
<i>Eucalyptus</i>	219	98.63	97.26	96.80	95.89	97.26	97.72
<i>Acácia</i>	212	99.06	98.11	98.58	99.53	98.58	99.06
Pastagem	212	99.06	98.11	98.58	92.45	96.70	96.23
Solo	69	100.00	100.00	100.00	97.10	100.00	98.55
Água	129	100.00	100.00	100.00	100.00	100.00	100.00

TABELA XX - Distribuição de erros obtidos pela Rede Neural Multinível com *BackPropagation* para o conjunto de treinamento (em porcentagem)

RNA1	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	7.08	3.30	-----	0.00	1.89	1.89	0.00	0.00
<i>Eucalyptus</i>	1.37	0.46	0.46	-----	0.46	0.00	0.00	0.00
<i>Acácia</i>	0.94	0.47	0.47	0.00	-----	0.00	0.00	0.00
Pastagem	0.94	0.00	0.00	0.00	0.00	-----	0.94	0.00
Solo	0.00	0.00	0.00	0.00	0.00	0.00	-----	0.00
Água	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-----
RNA2	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	11.32	3.77	-----	0.94	1.89	4.72	0.00	0.00
<i>Eucalyptus</i>	2.74	1.83	0.46	-----	0.46	0.00	0.00	0.00
<i>Acácia</i>	1.89	1.42	0.47	0.00	-----	0.00	0.00	0.00
Pastagem	1.89	0.00	0.00	0.00	0.00	-----	1.89	0.00
Solo	0.00	0.00	0.00	0.00	0.00	0.00	-----	0.00
Água	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-----
RNA3	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	6.60	0.94	-----	0.94	2.36	2.36	0.00	0.00
<i>Eucalyptus</i>	3.20	0.46	2.28	-----	0.46	0.00	0.00	0.00
<i>Acácia</i>	1.42	0.47	0.94	0.00	-----	0.00	0.00	0.00
Pastagem	1.42	0.00	0.47	0.00	0.00	-----	0.94	0.00
Solo	0.00	0.00	0.00	0.00	0.00	0.00	-----	0.00
Água	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-----
RNA4	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	16.04	7.08	-----	1.89	2.36	4.72	0.00	0.00
<i>Eucalyptus</i>	4.11	1.83	2.28	-----	0.00	0.00	0.00	0.00
<i>Acácia</i>	0.47	0.00	0.47	0.00	-----	0.00	0.00	0.00
Pastagem	7.55	4.25	0.47	0.00	0.00	-----	2.36	0.47
Solo	2.90	1.45	0.00	0.00	0.00	1.45	-----	0.00
Água	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-----
RNA5	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	8.49	3.30	-----	0.94	2.36	1.89	0.00	0.00
<i>Eucalyptus</i>	2.74	0.46	0.91	-----	1.37	0.00	0.00	0.00
<i>Acácia</i>	1.42	0.94	0.47	0.00	-----	0.00	0.00	0.00
Pastagem	3.30	1.42	0.47	0.00	0.00	-----	1.42	0.00
Solo	0.00	0.00	0.00	0.00	0.00	0.00	-----	0.00
Água	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-----
RNA6	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	7.55	4.72	-----	0.00	1.89	0.94	0.00	0.00
<i>Eucalyptus</i>	2.28	2.28	0.00	-----	0.00	0.00	0.00	0.00
<i>Acácia</i>	0.94	0.47	0.47	0.00	-----	0.00	0.00	0.00
Pastagem	3.77	2.83	0.47	0.00	0.00	-----	0.47	0.00
Solo	1.45	1.45	0.00	0.00	0.00	0.00	-----	0.00
Água	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-----

⁵⁰ Os termos RNA1, RNA2...RNA6 se referem, respectivamente, aos testes 01, 02...06 realizados pela Rede Neural Artificial Multinível com BackPropagation conforme descrito na seção 5.5.3.

TABELA XXI - Acertos obtidos pela Rede Neural Multinível com *BackPropagation* para o conjunto de reconhecimento (em porcentagem)

	Total de Pontos	RNA1	RNA2	RNA3	RNA4	RNA5	RNA6
Nativa	60	56.67	51.67	63.33	60.00	53.33	61.67
<i>Eucalyptus</i>	60	38.33	43.33	36.67	30.00	35.00	31.67
<i>Acácia</i>	60	53.33	55.00	53.33	56.67	53.33	55.00
Pastagem	60	66.67	68.33	65.00	61.67	63.33	55.00
Solo	60	68.33	73.33	63.33	73.33	70.00	61.67
Água	60	46.67	56.67	71.67	65.00	53.33	78.33

TABELA XXII- Distribuição de erros obtidos pela Rede Neural Multinível com *BackPropagation* para o conjunto de reconhecimento (em porcentagem)

RNA1	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	43.33	5.00	-----	10.00	16.67	8.33	3.33	0.00
<i>Eucalyptus</i>	61.67	8.33	36.67	-----	16.67	0.00	0.00	0.00
<i>Acácia</i>	46.67	10.00	23.33	8.33	-----	5.00	0.00	0.00
Pastagem	33.33	0.00	20.00	0.00	1.67	-----	11.67	0.00
Solo	31.67	0.00	0.00	0.00	0.00	31.67	-----	0.00
Água	53.33	33.33	0.00	0.00	0.00	15.00	5.00	-----
RNA2	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	48.33	18.33	-----	3.33	13.33	10.00	3.33	0.00
<i>Eucalyptus</i>	56.67	10.00	30.00	-----	15.00	1.67	0.00	0.00
<i>Acácia</i>	45.00	13.33	18.33	10.00	-----	3.33	0.00	0.00
Pastagem	31.67	5.00	16.67	0.00	1.67	-----	8.33	0.00
Solo	26.67	0.00	0.00	0.00	0.00	26.67	-----	0.00
Água	43.33	6.67	0.00	0.00	0.00	35.00	1.67	-----
RNA3	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	36.67	1.67	-----	3.33	16.67	10.00	5.00	0.00
<i>Eucalyptus</i>	63.33	1.67	41.67	-----	16.67	3.33	0.00	0.00
<i>Acácia</i>	46.67	6.67	38.33	1.67	-----	0.00	0.00	0.00
Pastagem	35.00	1.67	21.67	0.00	1.67	-----	10.00	0.00
Solo	36.67	0.00	0.00	0.00	0.00	36.67	-----	0.00
Água	28.33	1.67	0.00	0.00	0.00	25.00	1.67	-----
RNA4	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	40.00	6.67	-----	5.00	15.00	8.33	3.33	1.67
<i>Eucalyptus</i>	70.00	11.67	45.00	-----	10.00	3.33	0.00	0.00
<i>Acácia</i>	43.33	8.33	26.67	1.67	-----	6.67	0.00	0.00
Pastagem	38.33	5.00	21.67	1.67	1.67	-----	6.67	1.67
Solo	26.67	1.67	1.67	0.00	0.00	23.33	-----	0.00
Água	35.00	5.00	1.67	0.00	0.00	28.33	0.00	-----
RNA5	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	46.67	6.67	-----	8.33	18.33	10.00	3.33	0.00
<i>Eucalyptus</i>	65.00	8.33	41.67	-----	11.67	3.33	0.00	0.00
<i>Acácia</i>	46.67	10.00	20.00	10.00	-----	6.67	0.00	0.00
Pastagem	36.67	6.67	20.00	0.00	0.00	-----	10.00	0.00
Solo	30.00	1.67	0.00	0.00	0.00	28.33	-----	0.00
Água	46.67	3.33	0.00	0.00	0.00	10.00	33.33	-----
RNA6	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	38.33	10.00	-----	5.00	11.67	8.33	3.33	0.00
<i>Eucalyptus</i>	68.33	16.67	38.33	-----	13.33	0.00	0.00	0.00
<i>Acácia</i>	45.00	13.33	21.67	6.67	-----	3.33	0.00	0.00
Pastagem	45.00	6.67	25.00	0.00	1.67	-----	10.00	1.67
Solo	38.33	8.33	0.00	0.00	0.00	30.00	-----	0.00
Água	21.67	6.67	0.00	0.00	0.00	15.00	0.00	-----

A partir dos dados das Tabelas de XV a XXII foi possível criar os gráficos e as Tabelas de Contingência do capítulo 6. Estas, por sua vez, foram montadas com a finalidade de aceitar ou não a hipótese nula (H_0 : NÃO existe diferença significativa entre o método de Máxima Verossimilhança Gaussiana e a Rede Neural Multinível com *BackPropagation*⁵¹), ao nível de significância de 5%. As Tabelas de Contingência foram criadas para cada uma das classes, em cada um dos seis conjuntos de bandas previamente selecionados, tanto para o conjunto de treinamento quanto para o de reconhecimento.

Conforme SPIEGEL (1978), cada frequência observada em uma Tabela de Contingência, de h linhas e k colunas, corresponde a uma frequência esperada, ou teórica, calculada com base em alguma hipótese de acordo com as regras de probabilidade. Assim, para uma tabela de 2 linhas x 2 colunas, é possível investigar a concordância entre frequências observadas e frequências esperadas da seguinte forma:

	I	II	TOTAL
A	a_1	a_2	n_A
B	b_1	b_2	n_B
	n_1	n_2	n

$$\chi^2_{\text{calc}} = \frac{n (a_1 b_2 - a_2 b_1)^2}{n_1 n_2 n_A n_B} \quad [5.1]$$

Lembra-se que n_1 , n_2 , n_A e n_B são as frequências totais (frequências marginais) das colunas e linhas, respectivamente. Segundo SPIEGEL (1978), caso $\chi^2_{\text{calc}} = 0$, as frequências observadas e esperadas concordam exatamente, enquanto que se $\chi^2_{\text{calc}} > 0$ elas NÃO concordam exatamente. Quanto maior for o valor do χ^2_{calc} tanto maior será a discrepância entre frequências esperadas e observadas.

Calculado o χ^2 , para todas as tabelas, o passo final foi compará-lo ao χ^2 tabulado ao nível de significância de 5%⁵² e para 1 grau de liberdade (gl)⁵³. Neste caso, surgem duas situações (SPIEGEL, 1978):

⁵¹ Ou seja, quaisquer diferenças observadas são devidas a meras flutuações de amostragem da mesma população (SPIEGEL, 1978).

⁵² Isto significa que em cerca de 5 chances em 100 rejeitaria-se a hipótese H_0 quando ela deveria ser aceita, ou seja, pode-se ter 95% de confiança em que se tenha tomado a decisão certa (SPIEGEL, 1978).

⁵³ Conforme SPIEGEL (1978), o grau de liberdade é dado por $(h-1)(k-1)$, se as frequências esperadas podem ser calculadas, sem necessidade de estimar parâmetros da população, a partir da estatística amostral. Caso contrário, é dado por: $(h-1)(k-1)-m$, sendo m o número de parâmetros da população calculados a partir da estatística amostral.

- $\chi^2_{\text{calc}} < \chi^2_{\text{tab}}$: os resultados NÃO SÃO SIGNIFICATIVOS ao nível de significância de 5%. Assim, NÃO é possível rejeitar H_0 a este nível. Então, conclui-se que existe diferença significativa entre ambos os métodos ou não se formula decisão até que se tenha o resultado de novos testes.
- $\chi^2_{\text{calc}} > \chi^2_{\text{tab}}$: rejeita-se H_0 ou, pelo menos, não a aceita ao nível de 5%.

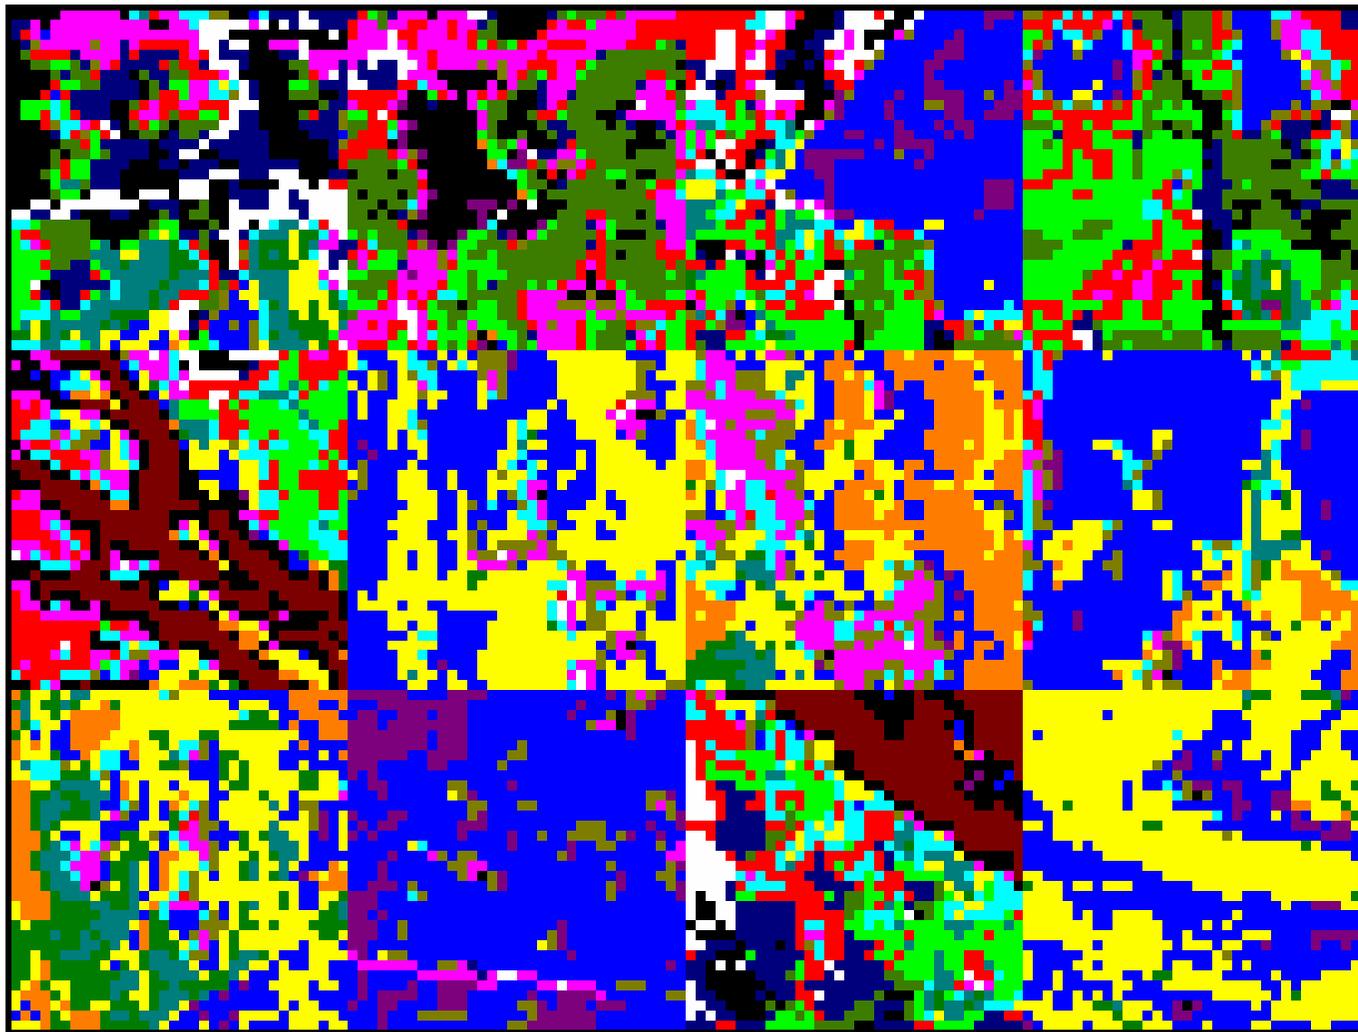
6 RESULTADOS

As Figuras 6.1 e 6.2 mostram as *clusterizações* obtidas pelo método do Histograma Tridimensional, enquanto que as Figuras 6.3, 6.4 e 6.5 ilustram os resultados obtidos por *Kohonen*. Os mosaicos *clusterizados* podem ser comparados com as *imagettes* mapeadas (Anexo 10) a fim de verificar a similaridade com a verdade terrestre.

Já as Figuras de 6.6 a 6.11 mostram os resultados das classificações obtidas pelo método de Máxima Verossimilhança Gaussiana, enquanto que as Figuras de 6.12 a 6.17 ilustram as doze áreas amostrais classificadas pela Rede Neural Multinível com *BackPropagation*.

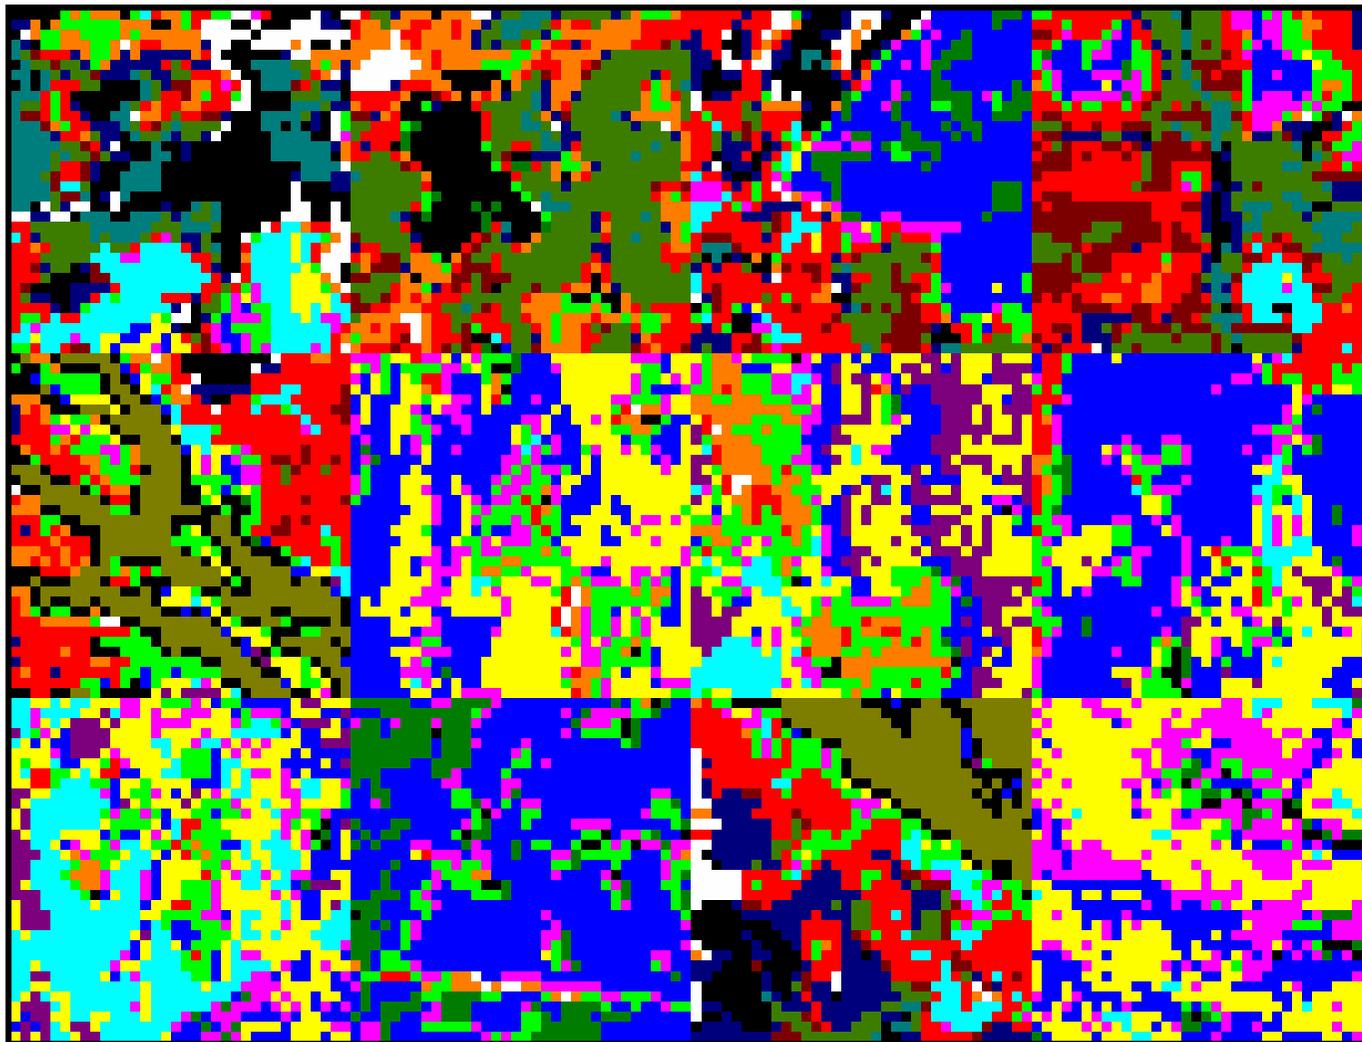
A acurácia obtida, por ambos os classificadores supervisionados, para os seis conjuntos de bandas, é apresentada nas Figuras de 6.18 a 6.29. Nota-se que os gráficos mostram a acurácia obtida (em porcentagem), por classe, tanto para o conjunto de treinamento quanto para o de reconhecimento. Por fim, as Tabelas de XXIII a XXXIV apresentam os testes de hipóteses realizados.

No próximo capítulo, estes resultados serão explicados, interpretados e comparados conforme os objetivos propostos.



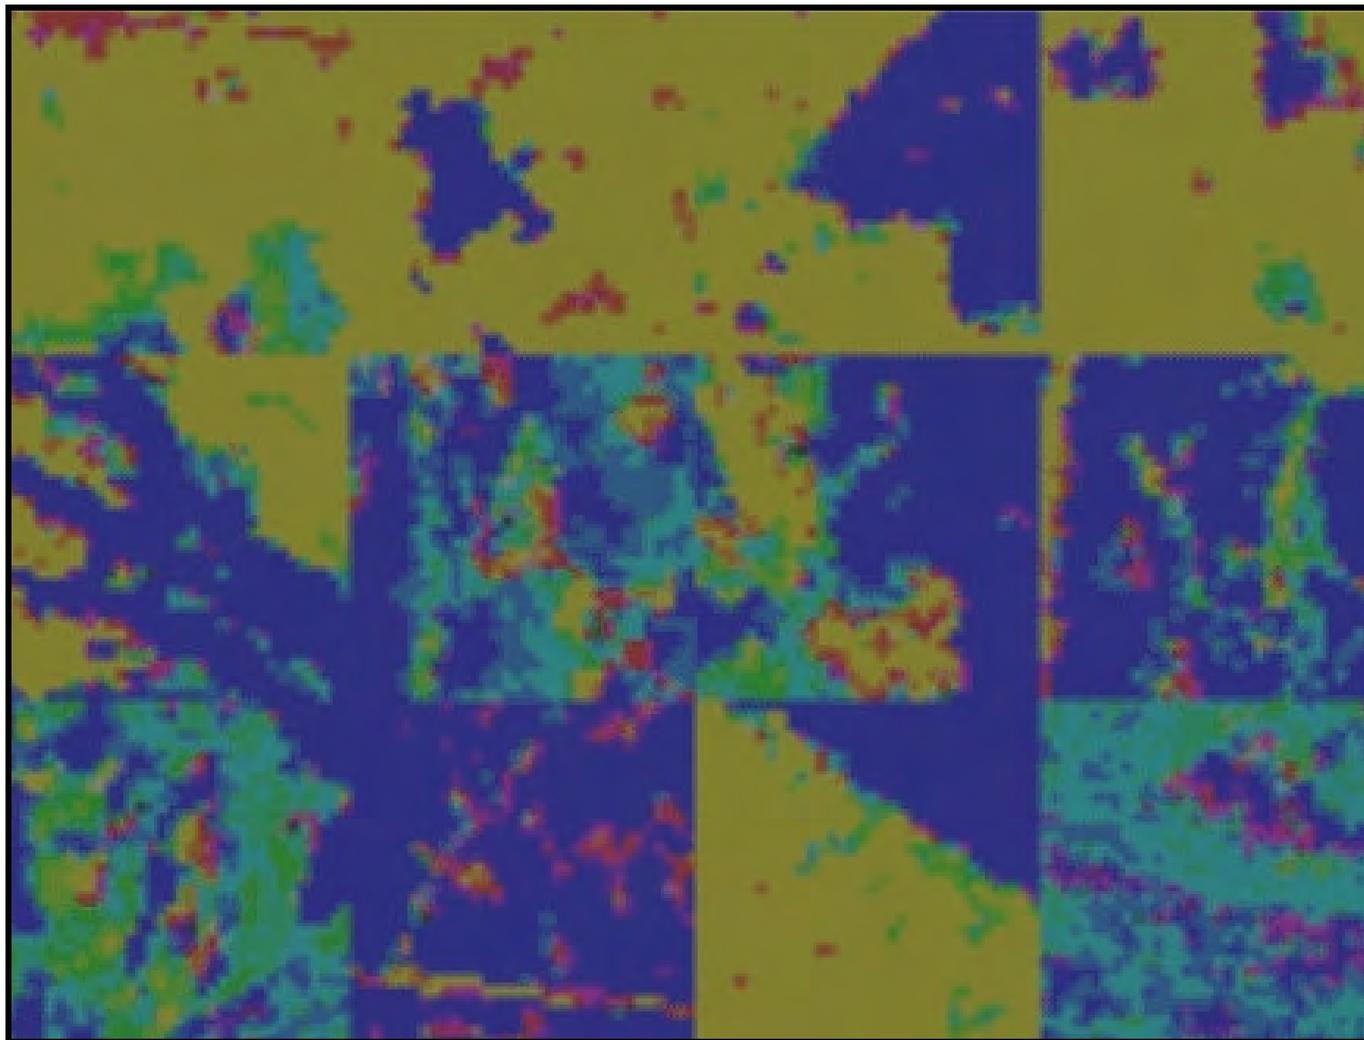
2.5 de saturação
exclusão dos *pixels* menos signifi-
cativos
abordagem fina

FIGURA 6.1 - *Clusterização* das áreas amostrais pelo método do Histograma Tridimensional. Bandas 345



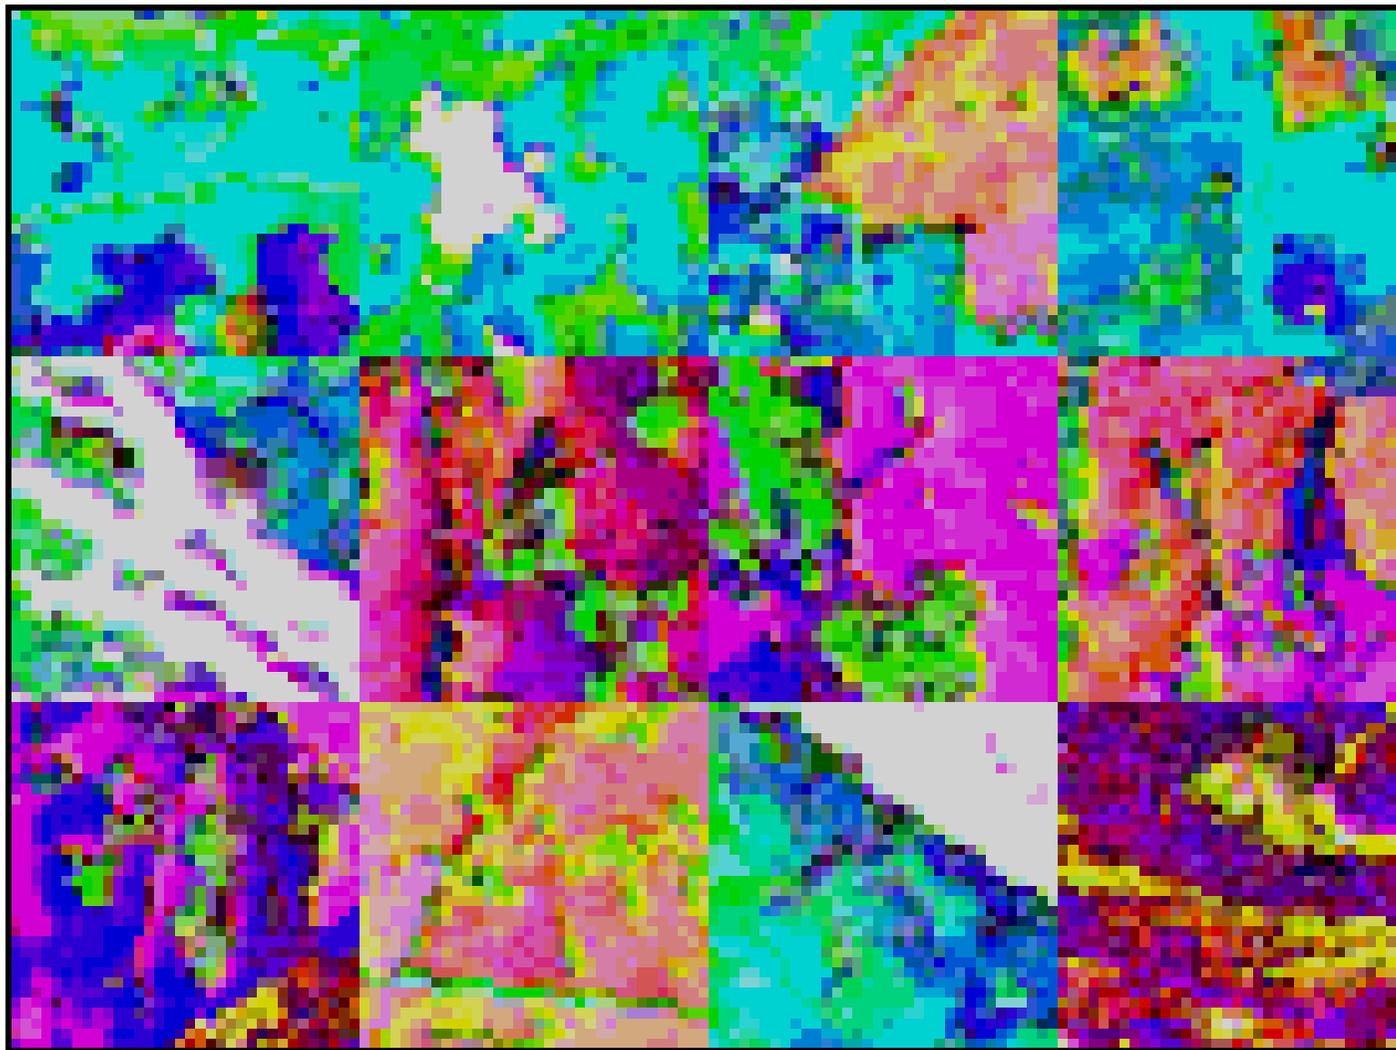
2.5 de saturação
exclusão dos *pixels* menos signifi-
cativos
abordagem fina

FIGURA 6.2 - *Clusterização* das áreas amostrais pelo método do Histograma Tridimensional. Bandas 347



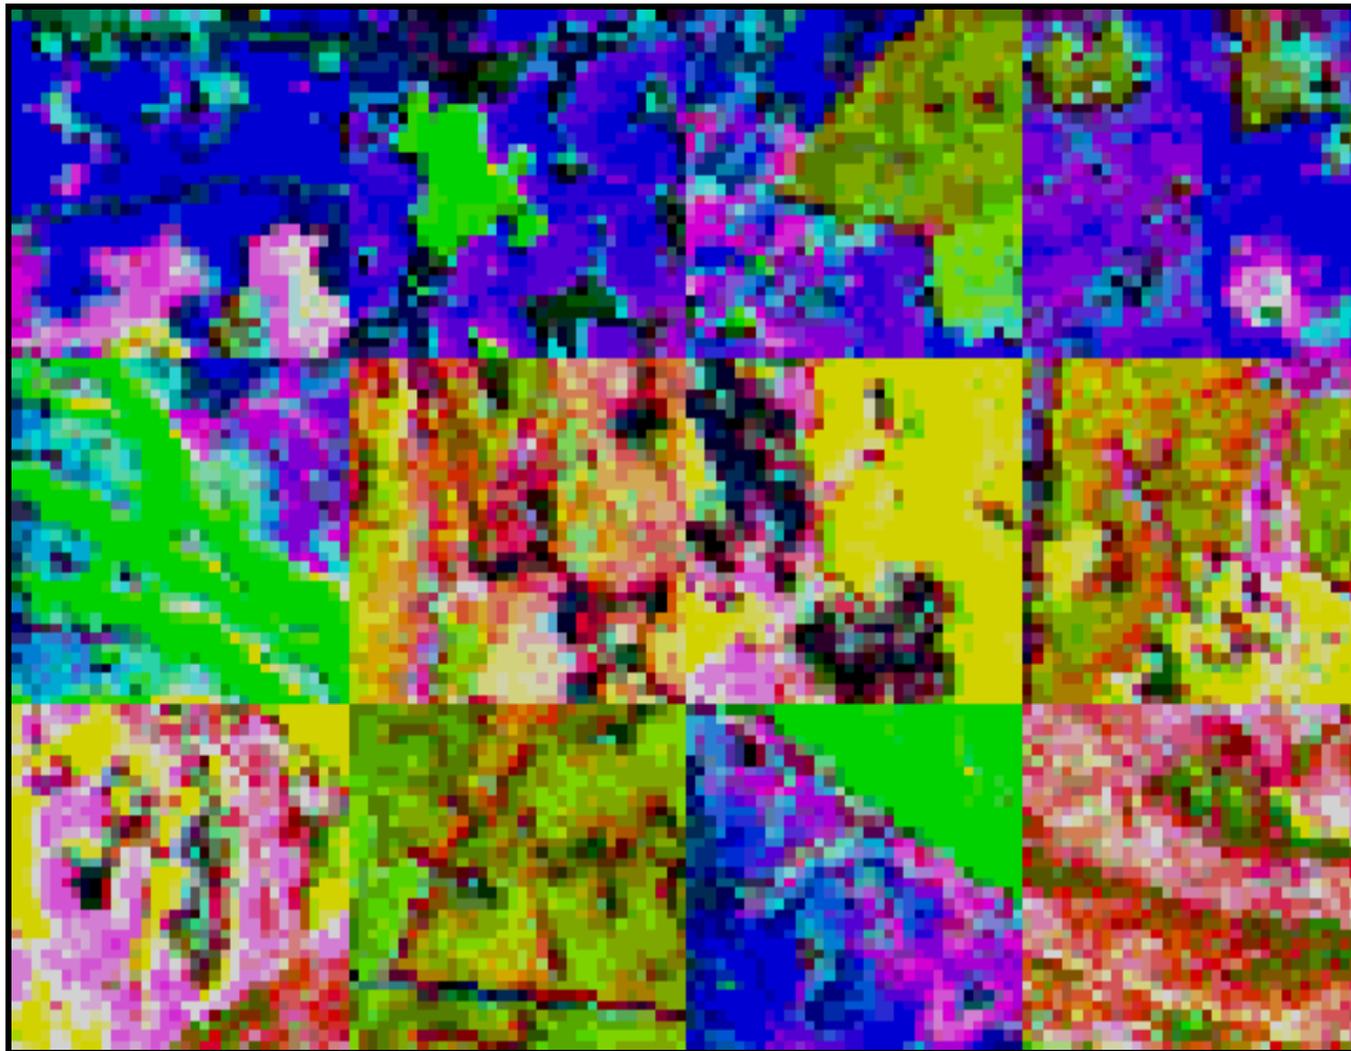
Dimensão do mapa: 3
Iterações: 150.000
Sigma: 2.0
Coef. aprendido: 0.01

FIGURA 6.3 - *Clusterização* das áreas amostrais por *Kohonen*. Bandas 345



Dimensão do mapa: 6
Iterações: 50.000
Sigma: 3.0
Coef. aprendido: 0.5

FIGURA 6.4 - *Clusterização* das áreas amostrais por *Kohonen*. Bandas 23457



Dimensão do mapa: 6
Iterações: 50.000
Sigma: 3.0
Coef. aprendido: 0.5

FIGURA 6.5 - *Clusterização* das áreas amostrais por *Kohonen*. Bandas 123457

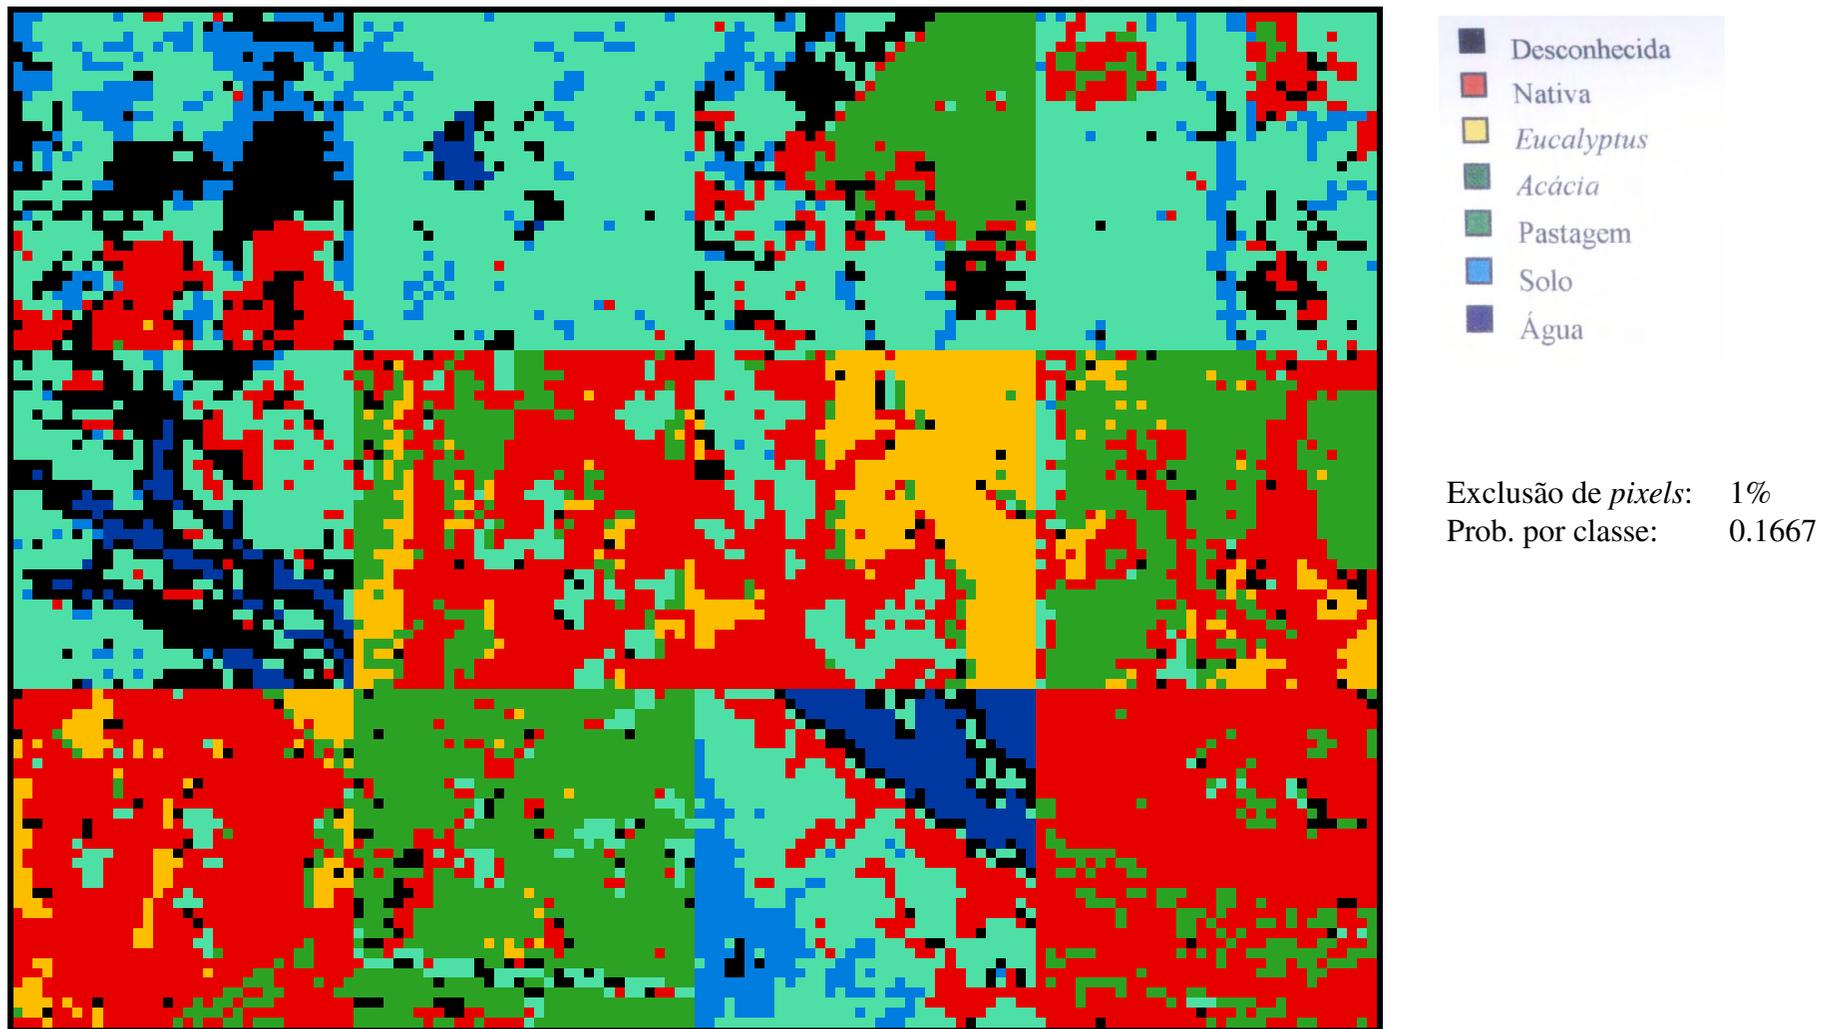


FIGURA 6.6 - Classificação por MAXVER. Bandas 123457

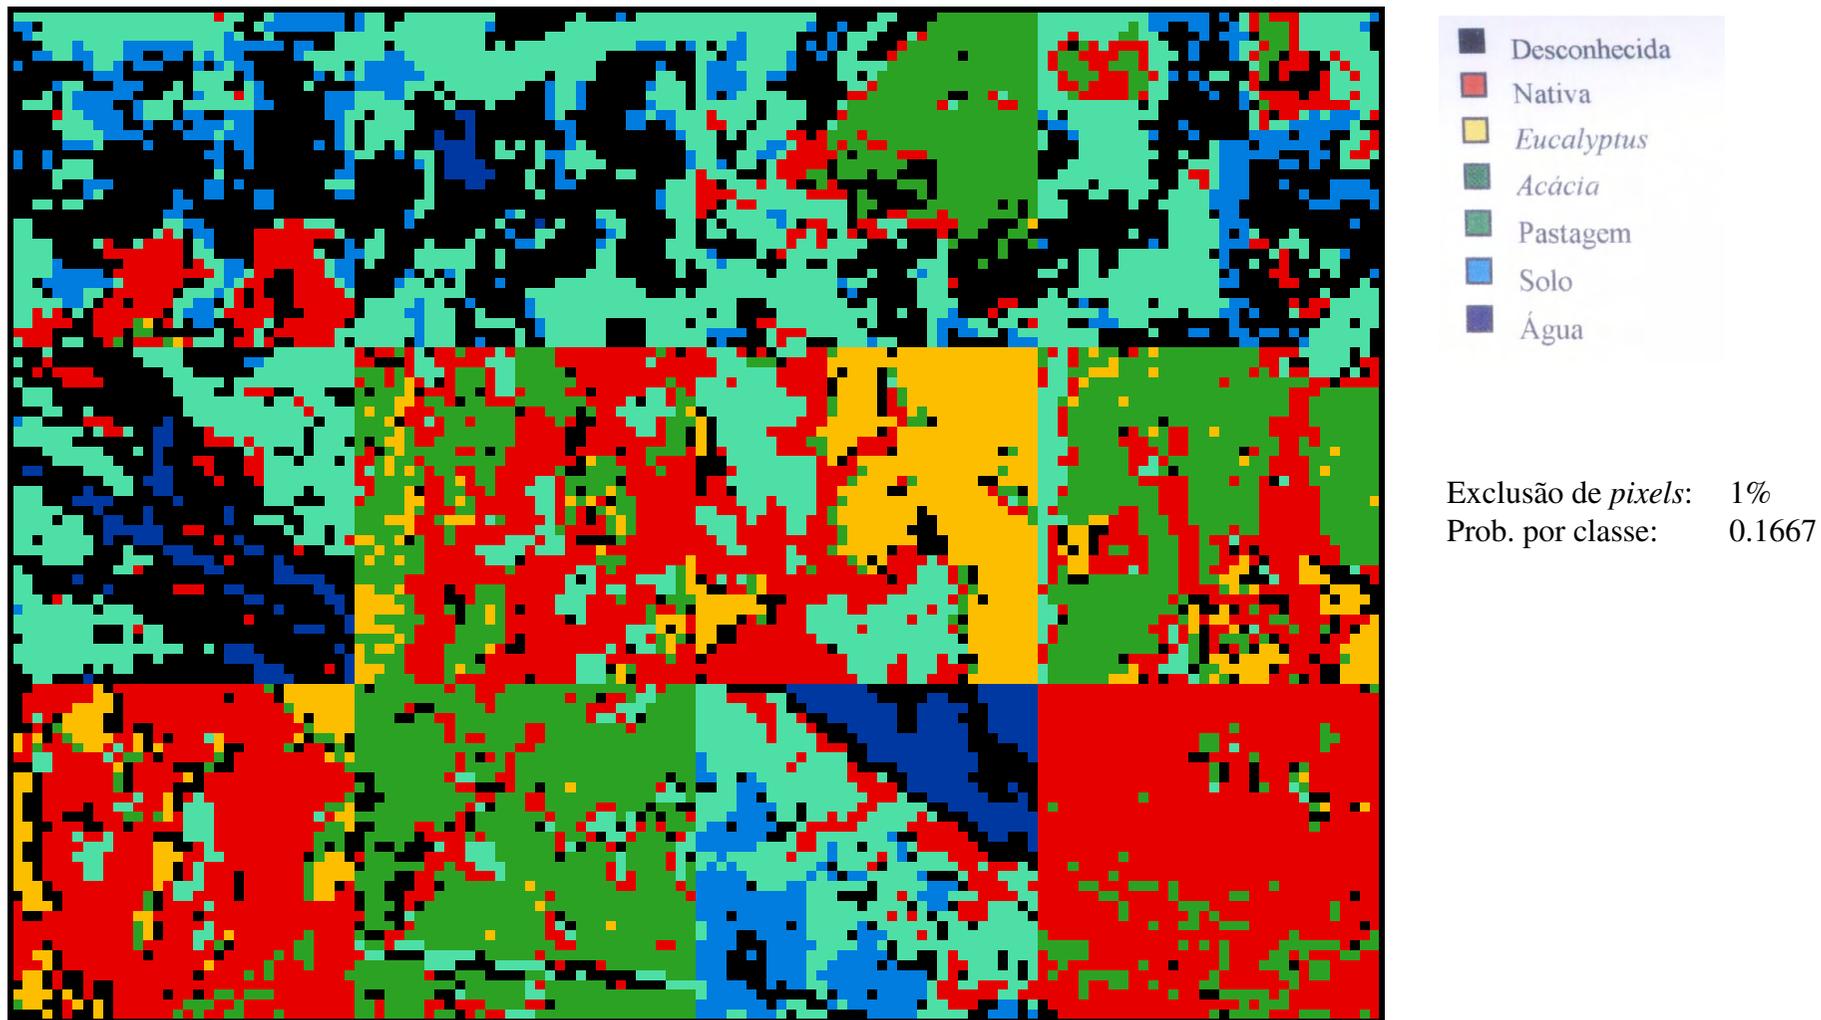
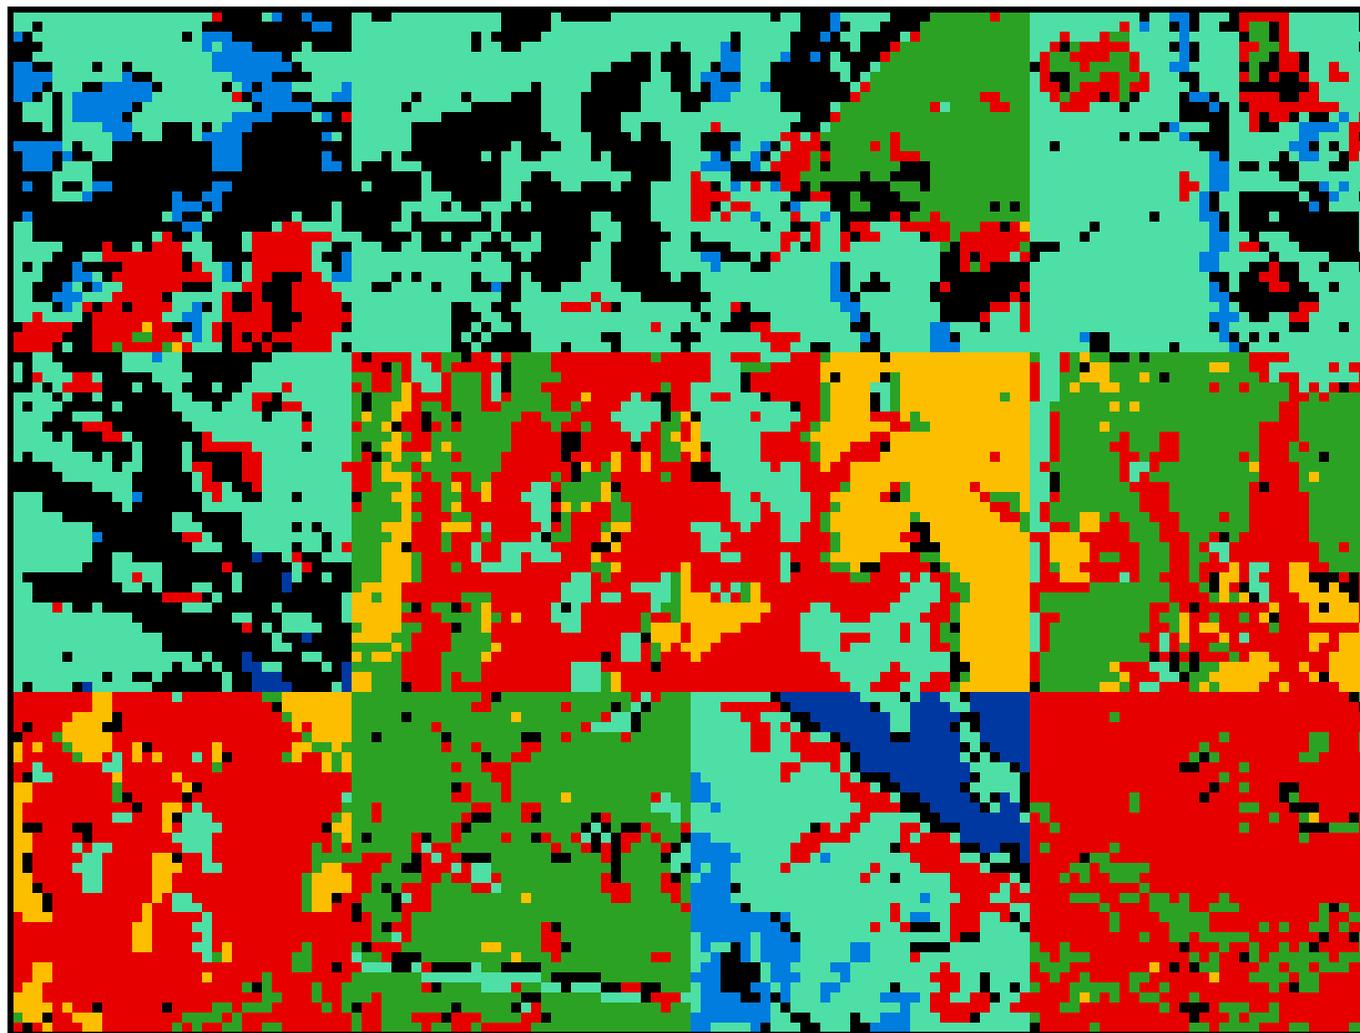


FIGURA 6.7 - Classificação por MAXVER. Bandas 12345



- Desconhecida
- Nativa
- *Eucalyptus*
- *Acácia*
- Pastagem
- Solo
- Água

Exclusão de *pixels*: 1%
 Prob. por classe: 0.1667

FIGURA 6.8 - Classificação por MAXVER. Bandas 13457

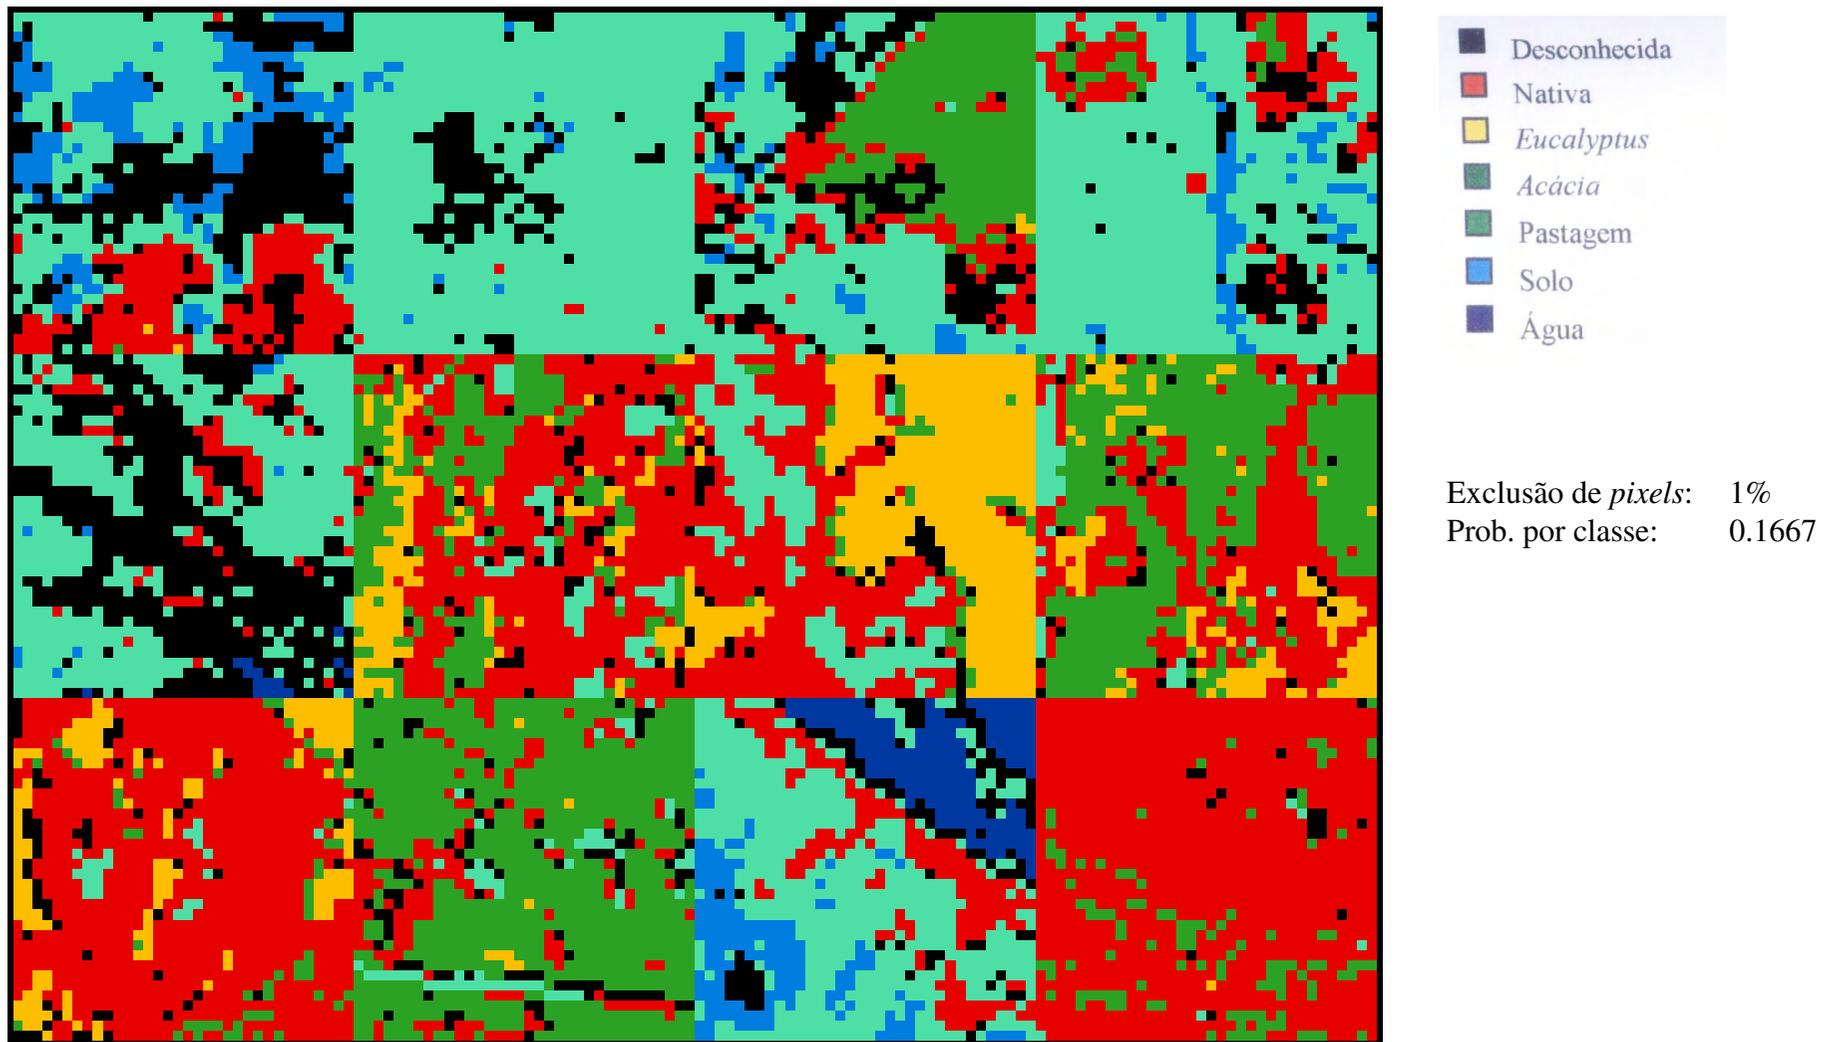
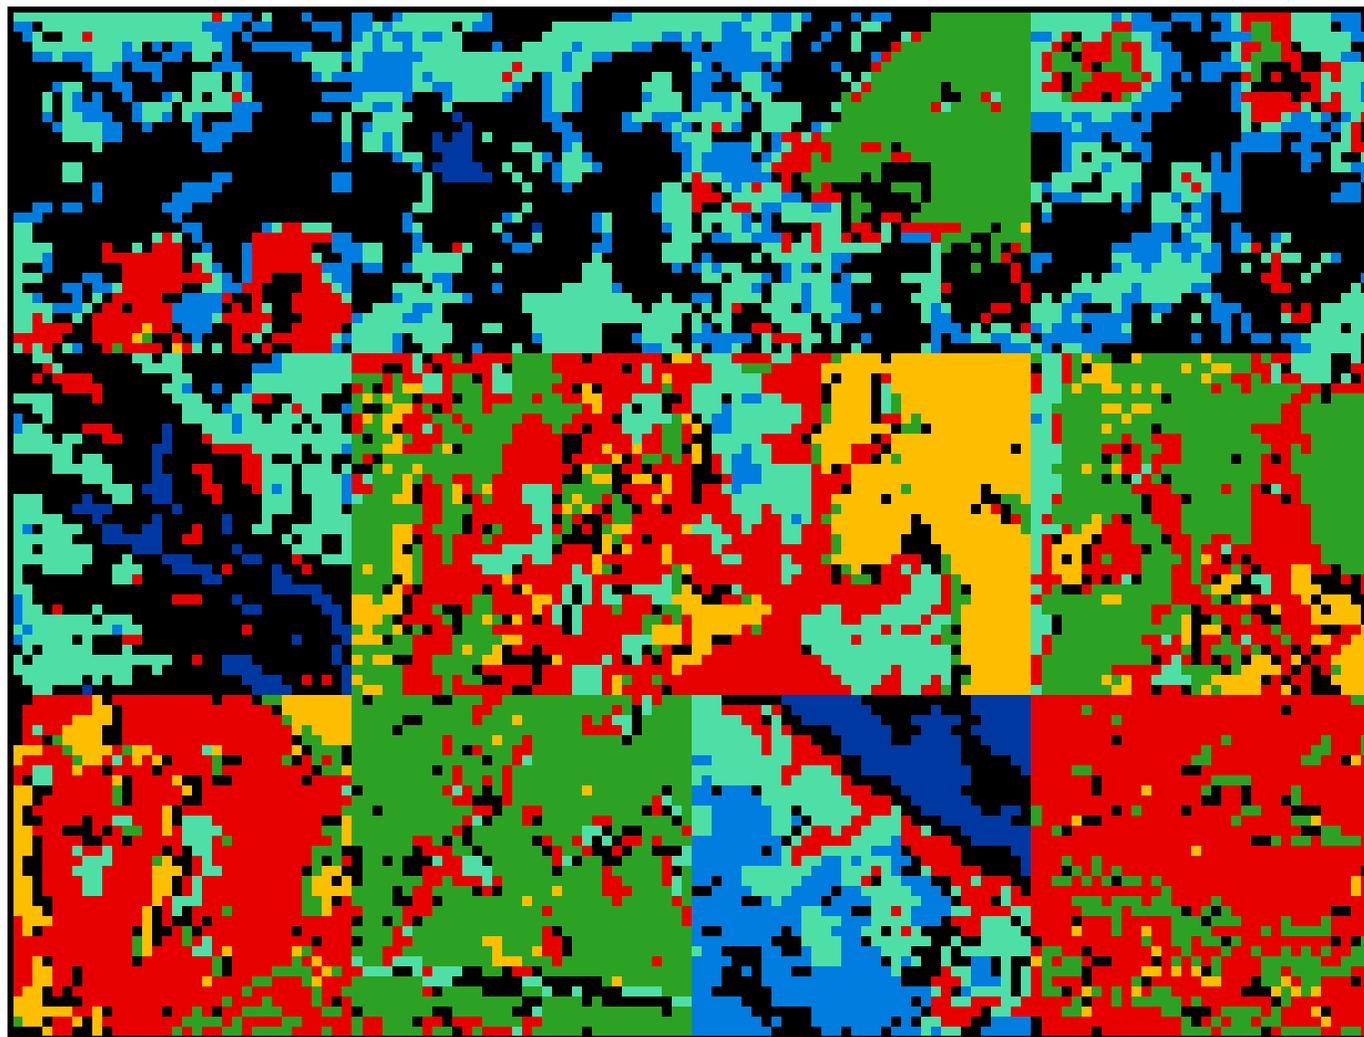


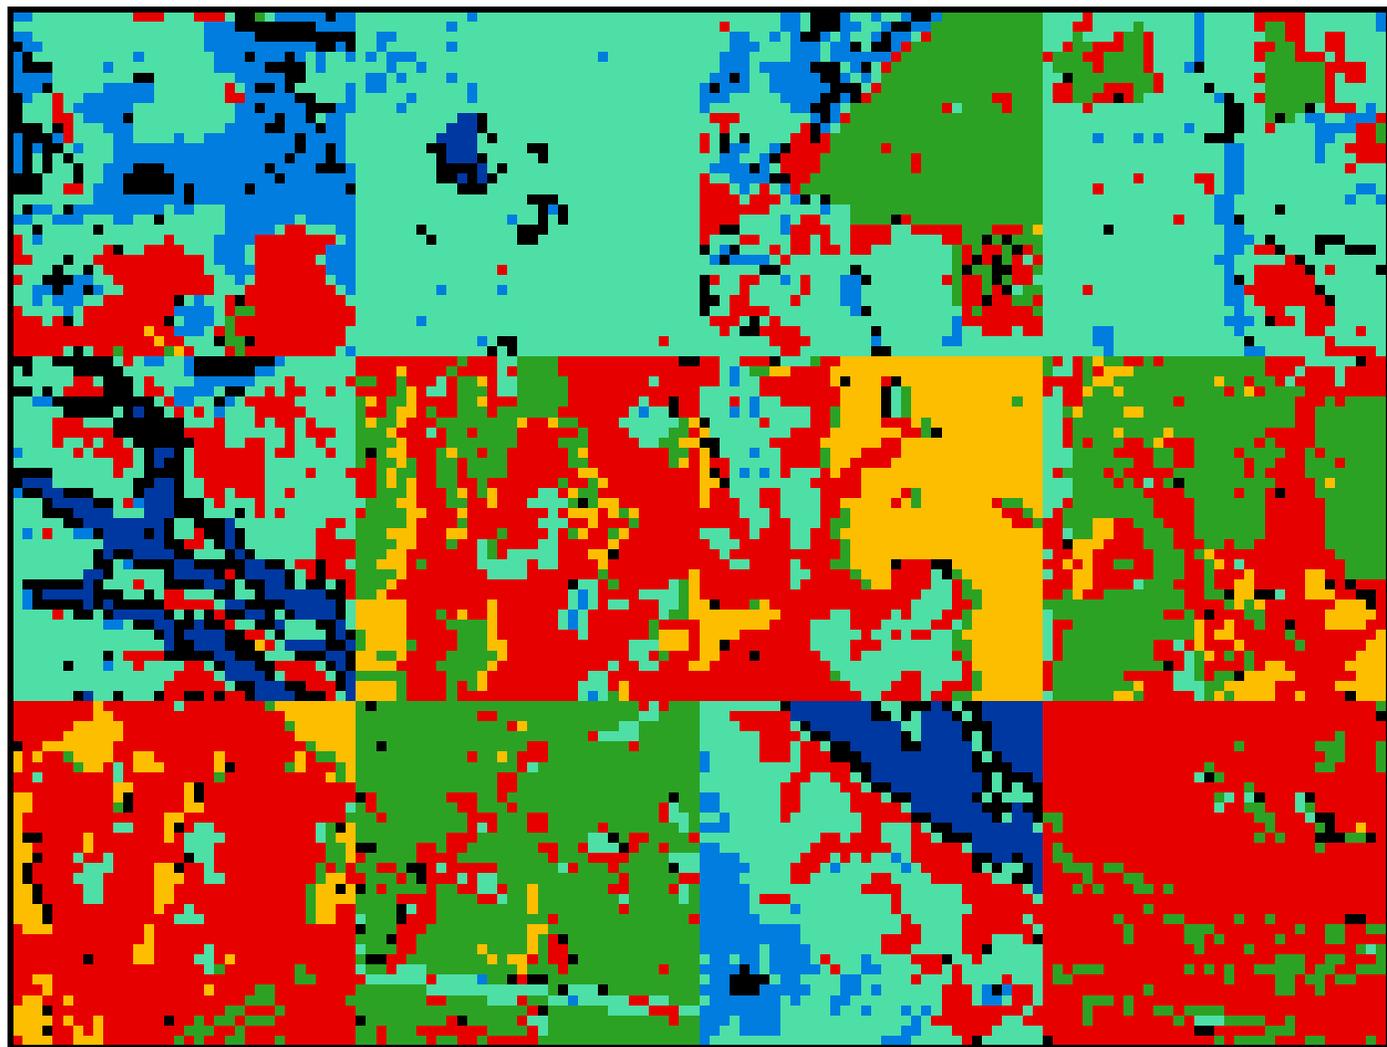
FIGURA 6.9 - Classificação por MAXVER. Bandas 12457



- Desconhecida
- Nativa
- *Eucalyptus*
- *Acácia*
- Pastagem
- Solo
- Água

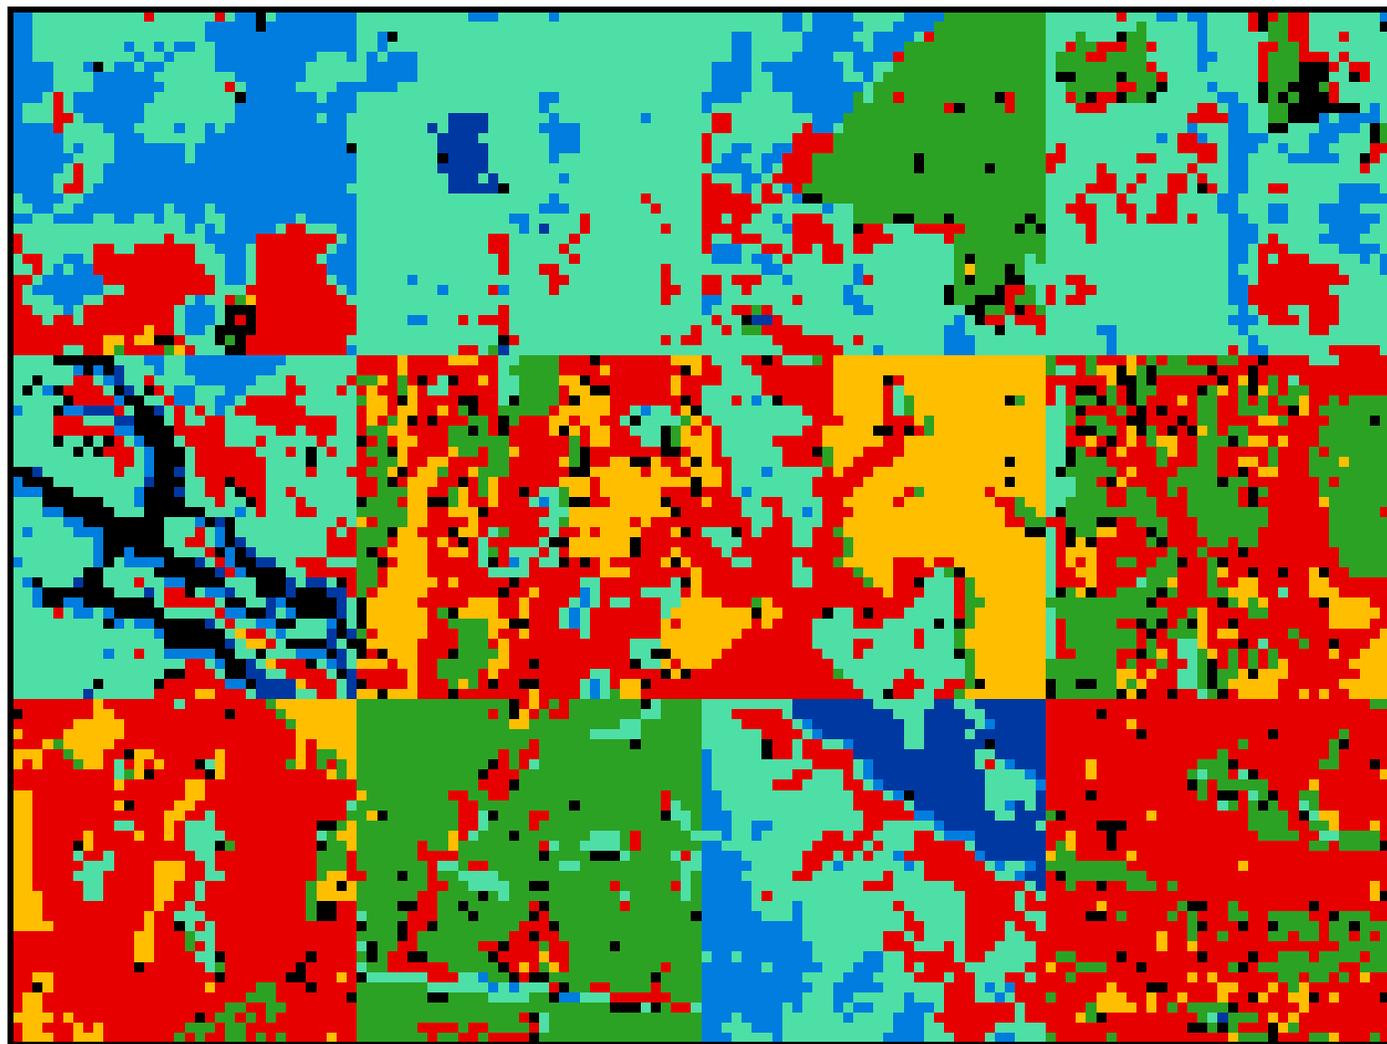
Exclusão de *pixels*: 1%
Prob. por classe: 0.1667

FIGURA 6.10 - Classificação por MAXVER. Bandas 12347



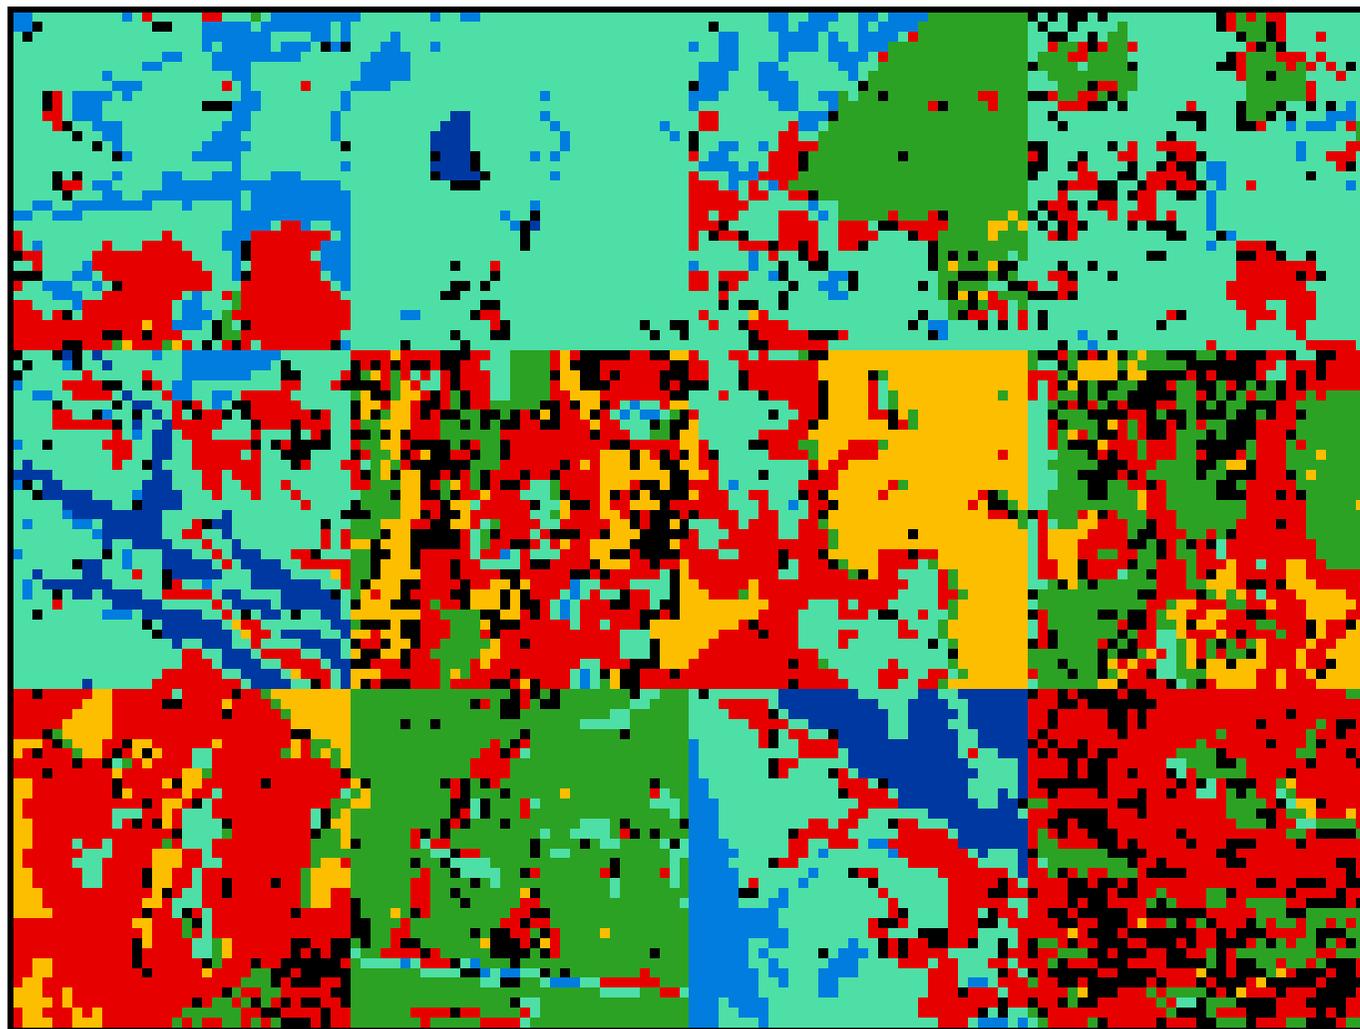
Exclusão de *pixels*: 1%
 Prob. por classe: 0.1667

FIGURA 6.11 - Classificação por MAXVER. Bandas 23457



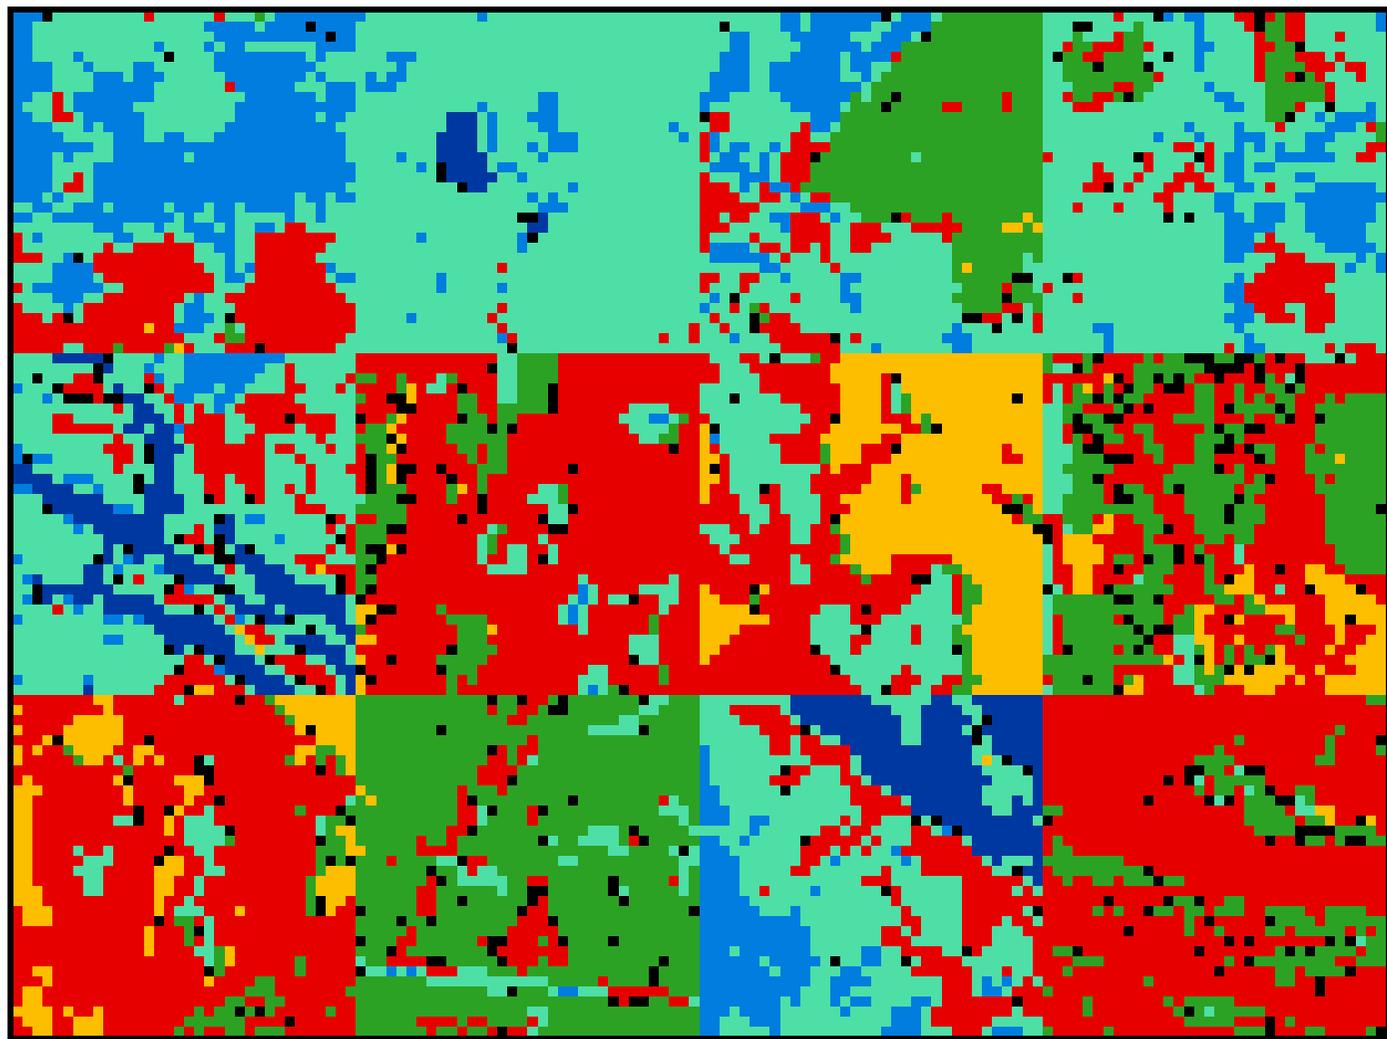
Nº neu. entr.	6
Nº neu. interm.:	10
Nº neu. sai.:	6
Coef. aprend.:	0.01
Iterações:	50000
Erro médio quad.:	0.031627

FIGURA 6.12 - Classificação pela RNA. Bandas 123457



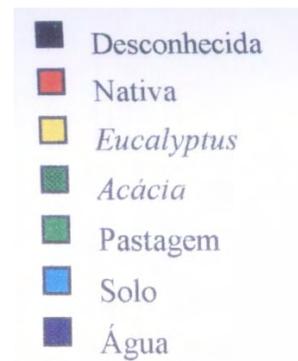
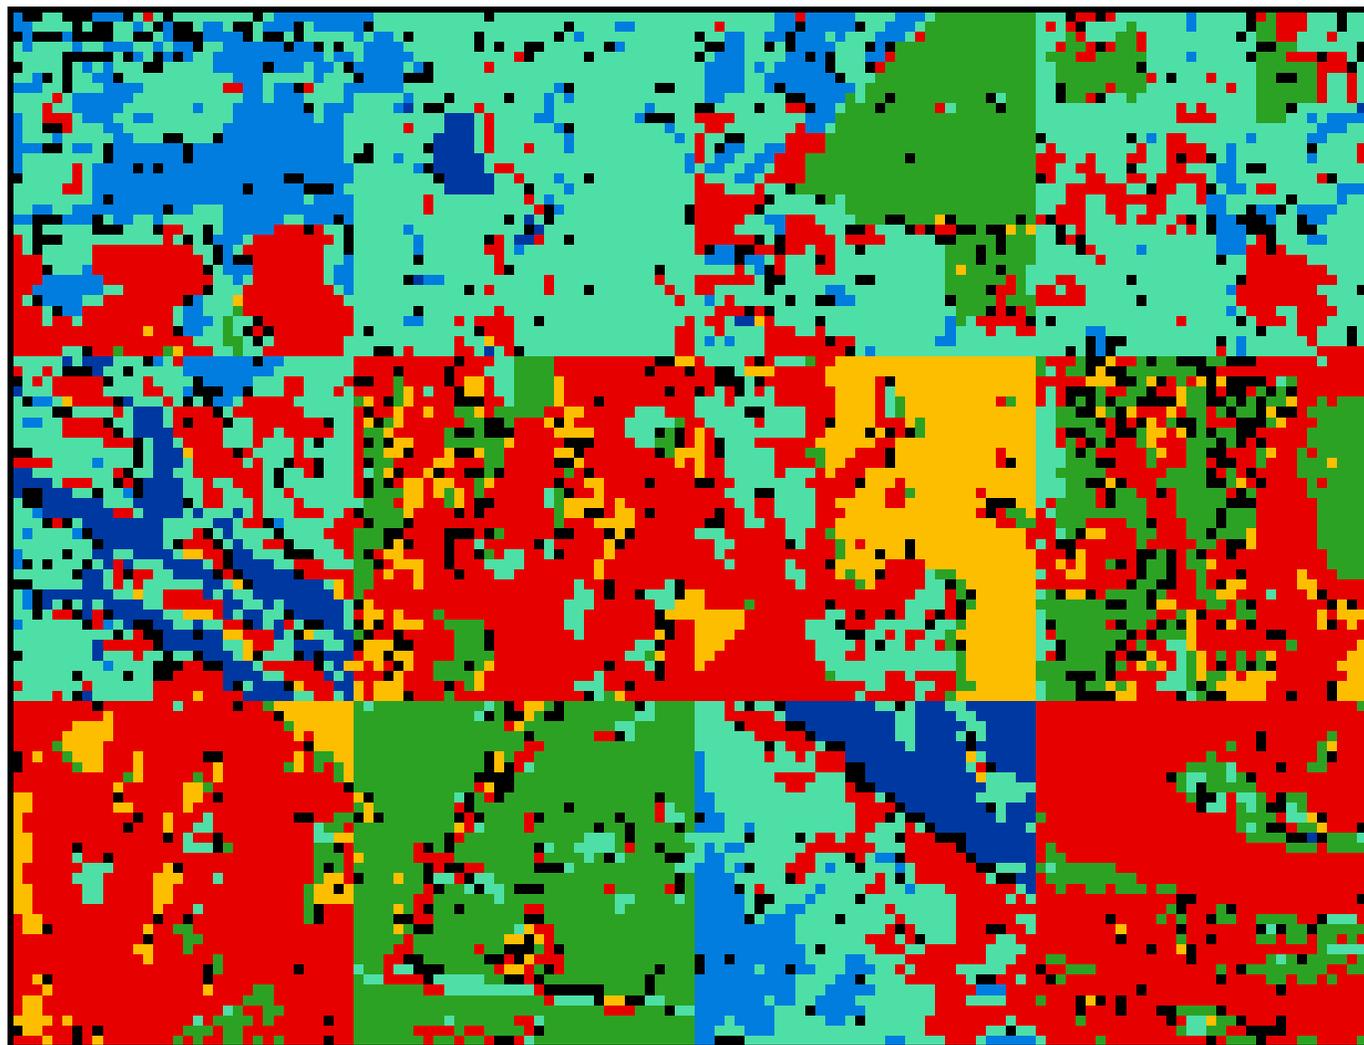
Nº neu. entr.	5
Nº neu. interm.:	10
Nº neu. sai.:	6
Coef. aprend.:	0.01
Iterações:	50000
Erro médio quad.:	0.082892

FIGURA 6.13 - Classificação pela RNA. Bandas 12345



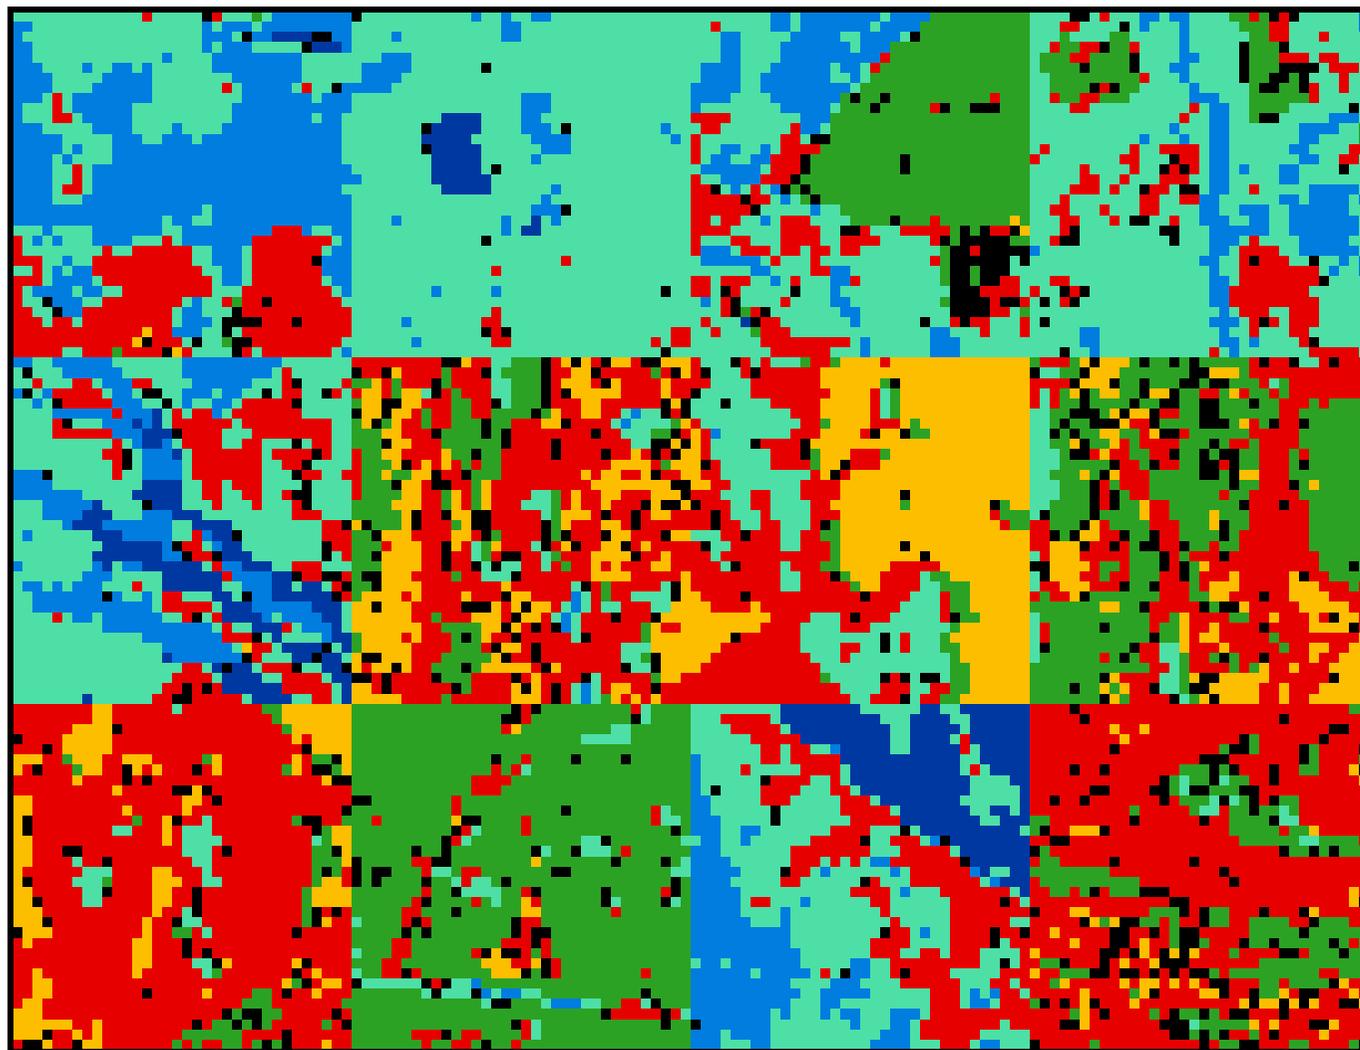
Nº neu. entr.	5
Nº neu. interm.:	10
Nº neu. sai.:	6
Coef. aprend.:	0.01
Iterações:	50000
Erro médio quad.:	0.056705

FIGURA 6.14 - Classificação pela RNA. Bandas 13457



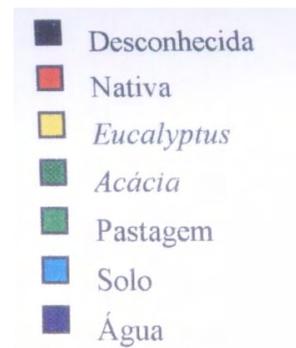
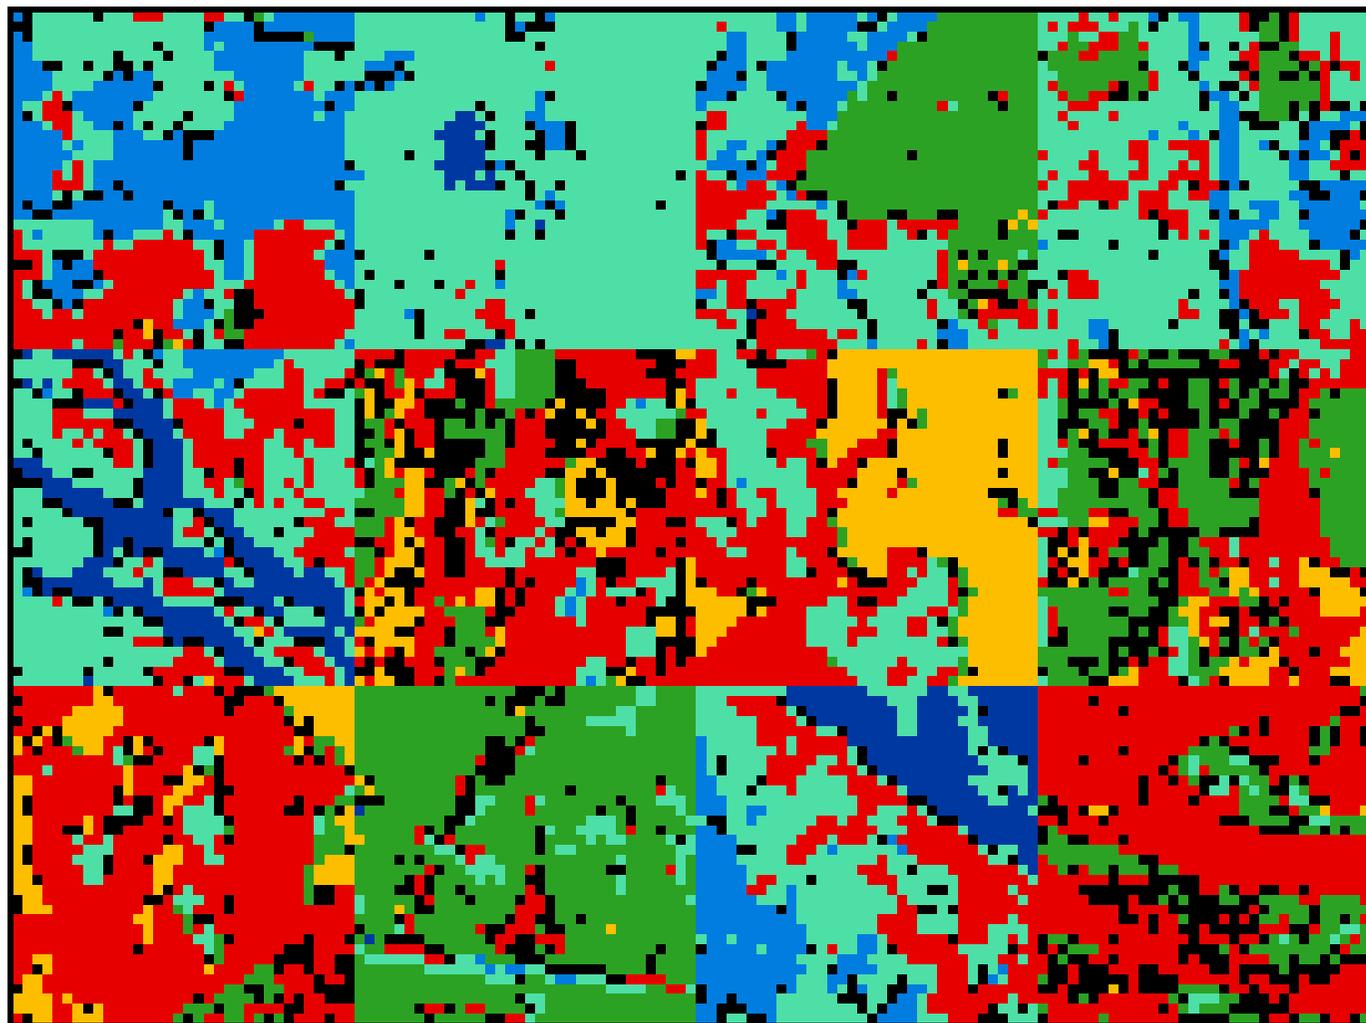
Nº neu. entr.	5
Nº neu. interm.:	10
Nº neu. sai.:	6
Coef. aprend.:	0.01
Iterações:	50000
Erro médio quad.:	0.089618

FIGURA 6.15 - Classificação pela RNA. Bandas 12457



Nº neu. entr.	5
Nº neu. interm.:	10
Nº neu. sai.:	6
Coef. aprend.:	0.01
Iterações:	50000
Erro médio quad.:	0.080239

FIGURA 6.16 - Classificação pela RNA. Bandas 12347



Nº neu. entr.	5
Nº neu. interm.:	10
Nº neu. sai.:	6
Coef. aprend.:	0.01
Iterações:	50000
Erro médio quad.:	0.054536

FIGURA 6.17 - Classificação pela RNA. Bandas 23457

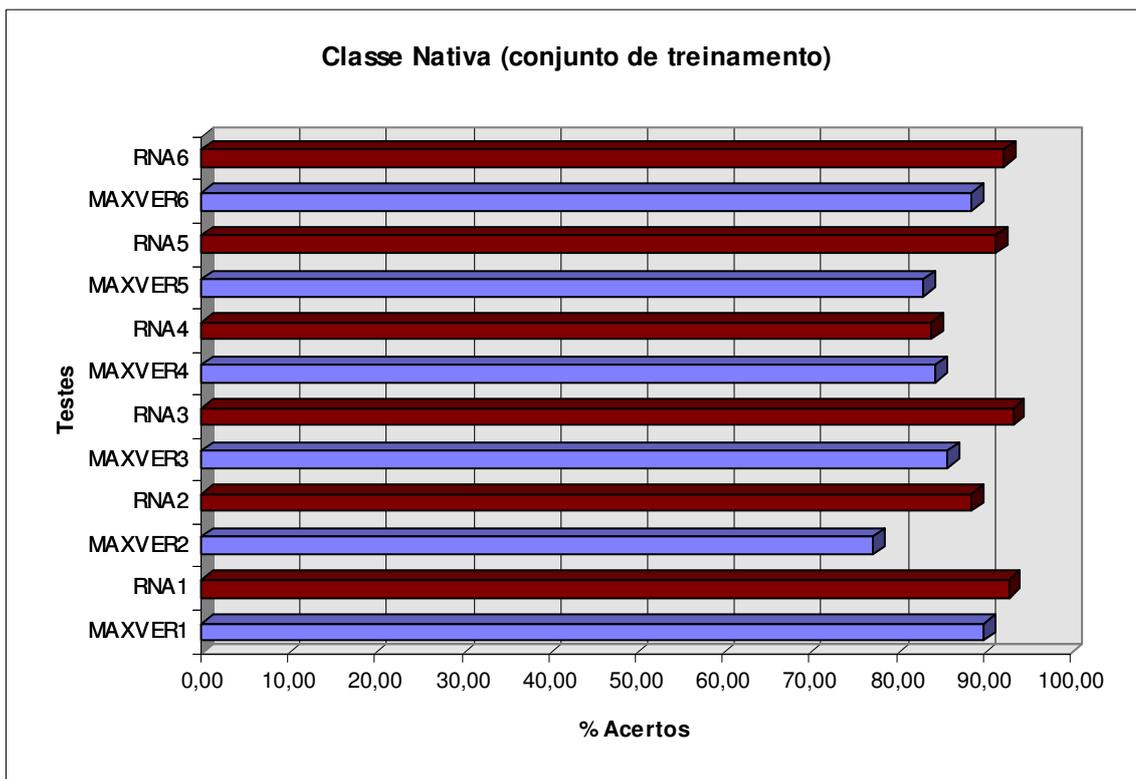


FIGURA 6.18 - Acurácia obtida para a classe Nativa (conjunto de treinamento)

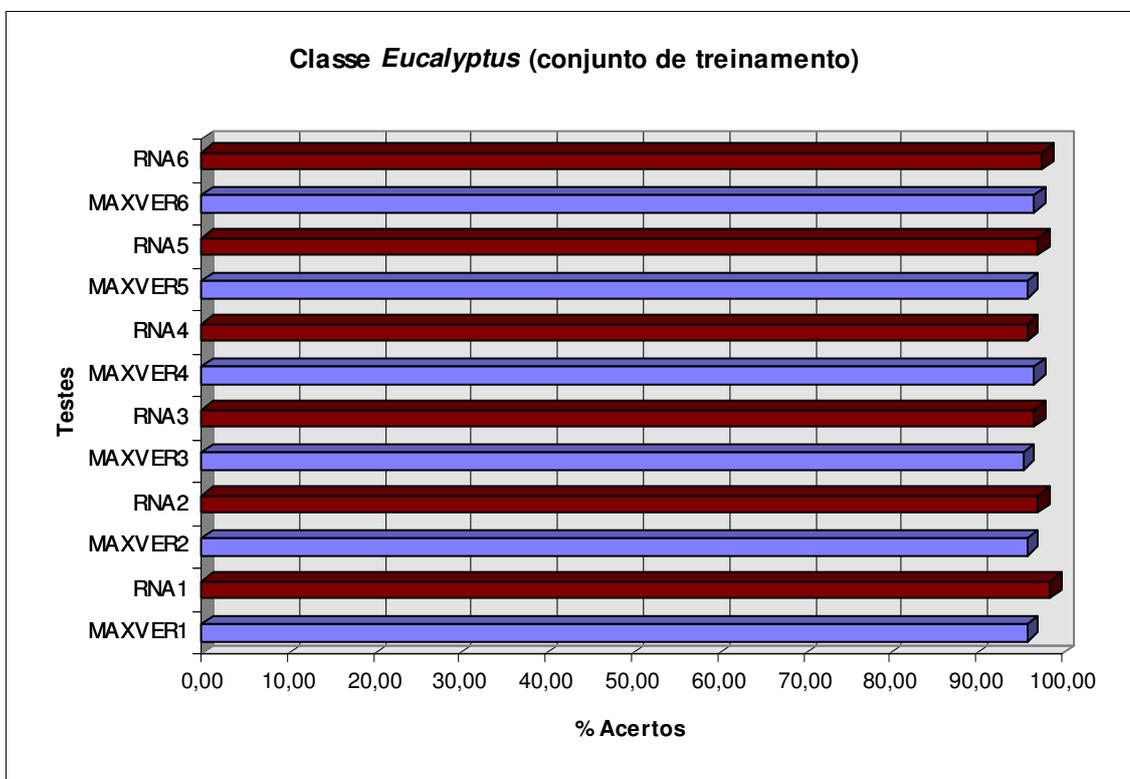


FIGURA 6.19 - Acurácia obtida para a classe *Eucalyptus* (conjunto de treinamento)

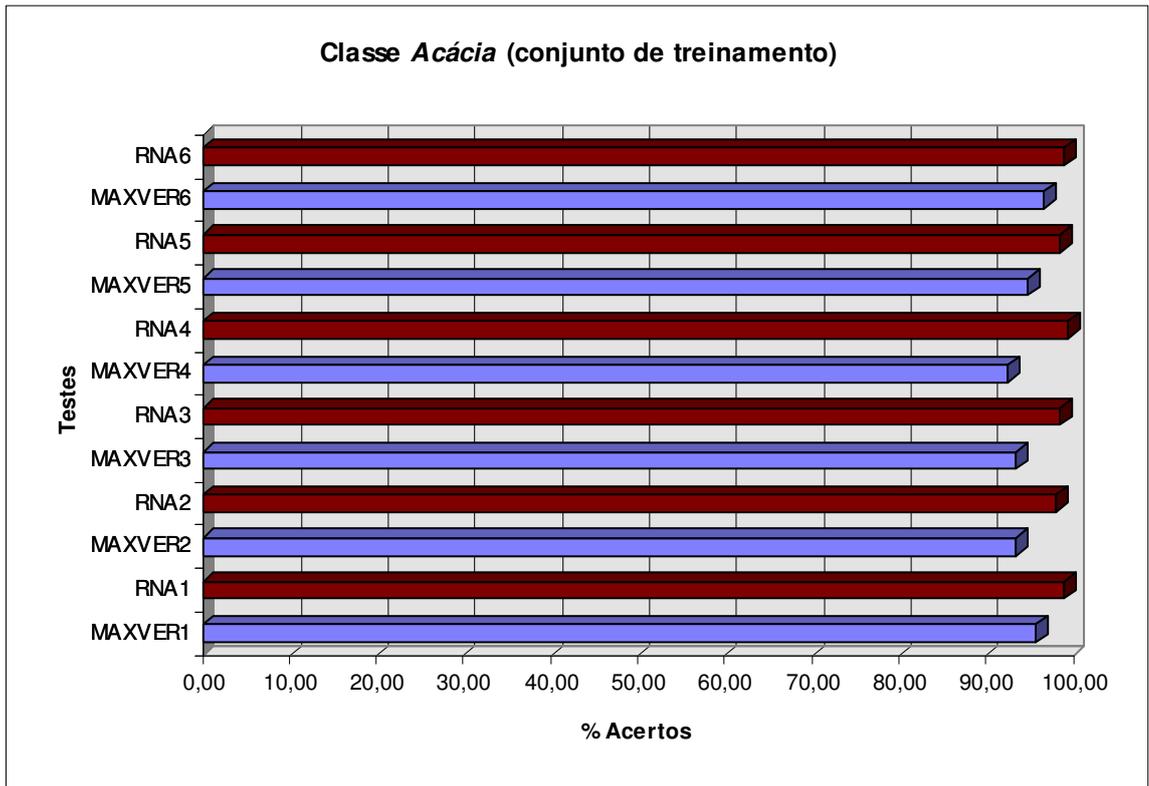


FIGURA 6.20 - Acurácia obtida para a classe *Acácia* (conjunto de treinamento)

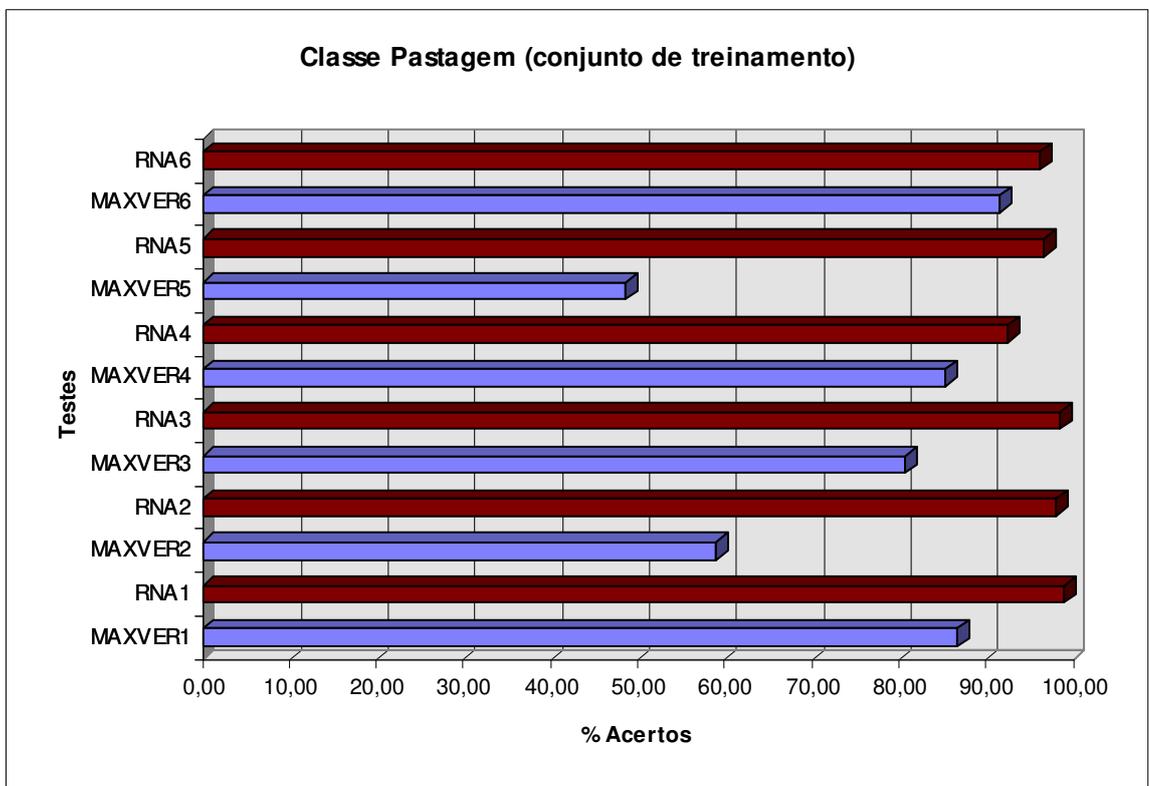


FIGURA 6.21 - Acurácia obtida para a classe *Pastagem* (conjunto de treinamento)

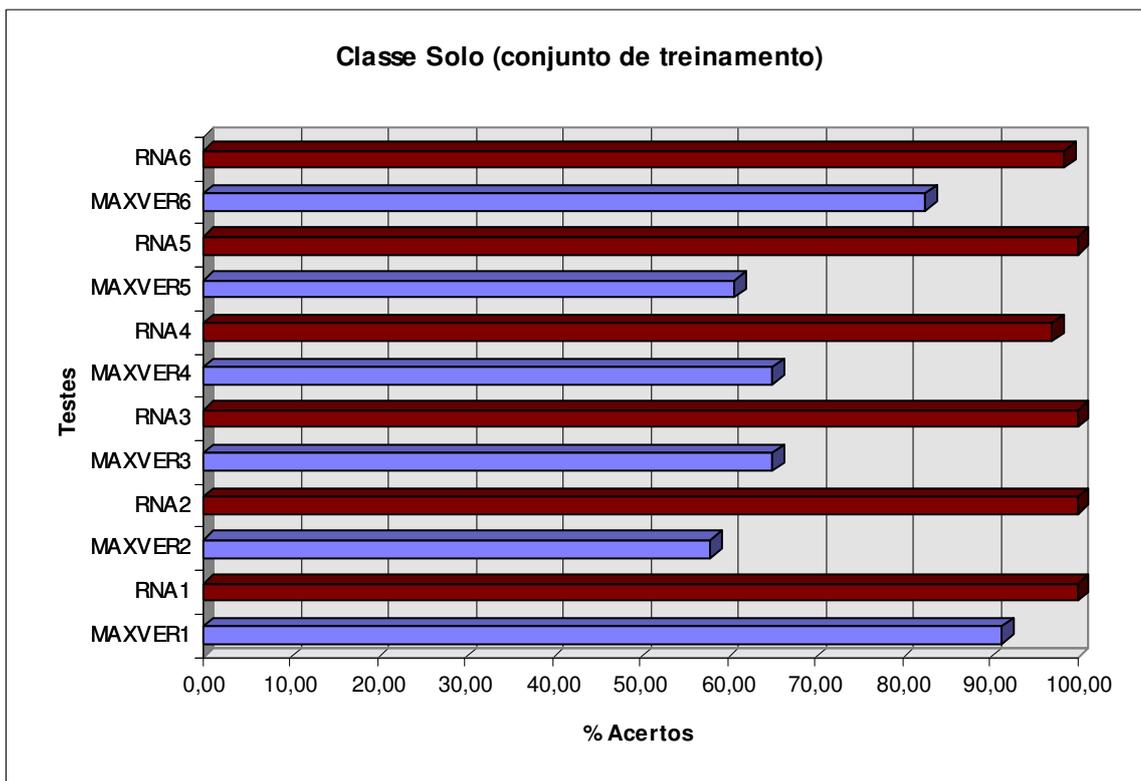


FIGURA 6.22 - Acurácia obtida para a classe Solo (conjunto de treinamento)

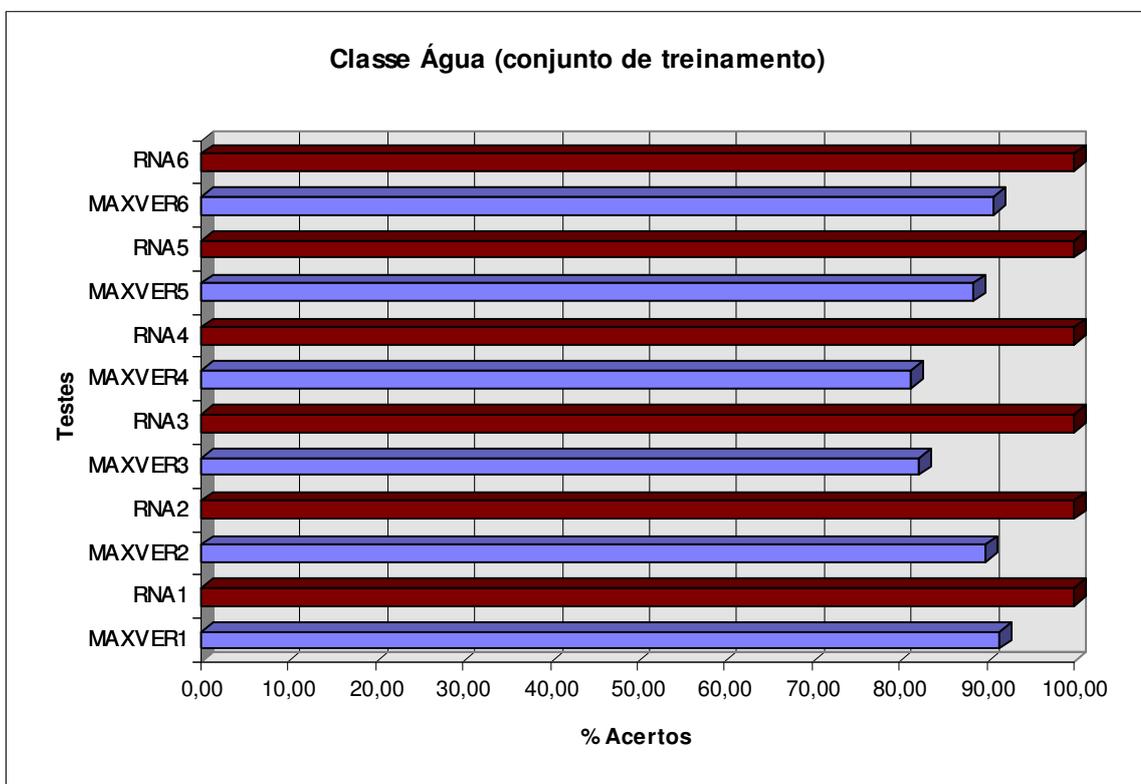


FIGURA 6.23 - Acurácia obtida para a classe Água (conjunto de treinamento)

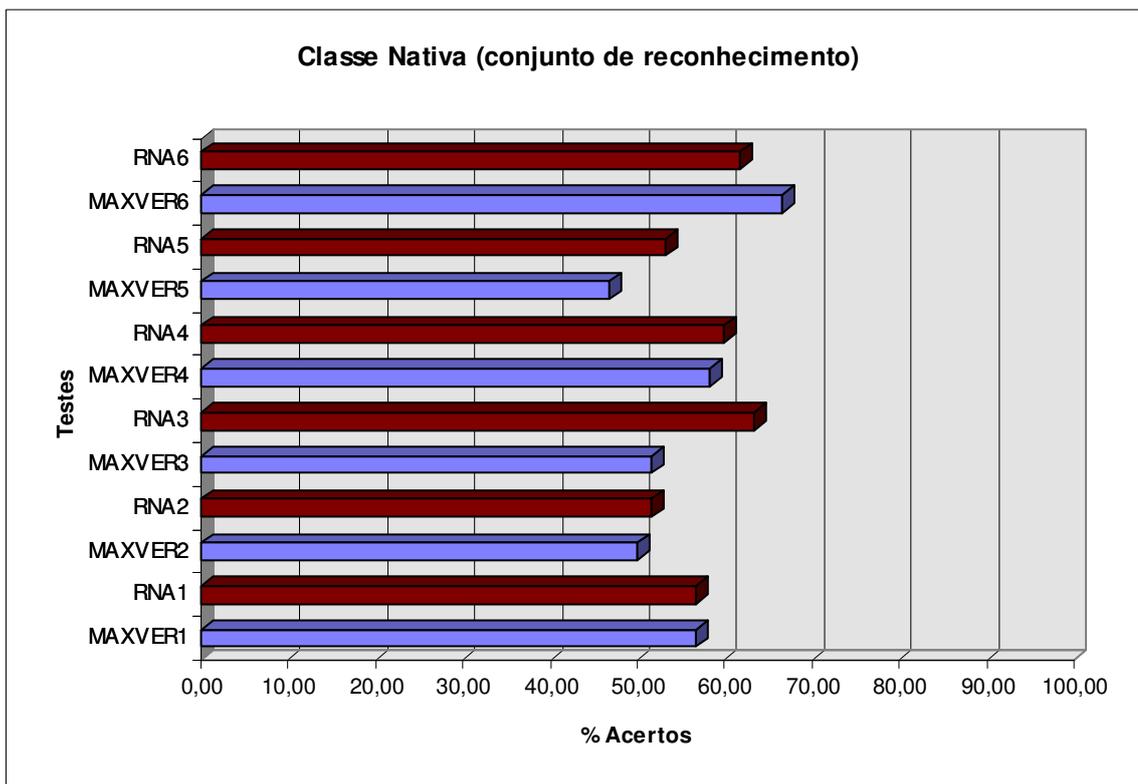


FIGURA 6.24 - Acurácia obtida para a classe Nativa (conjunto de reconhecimento)

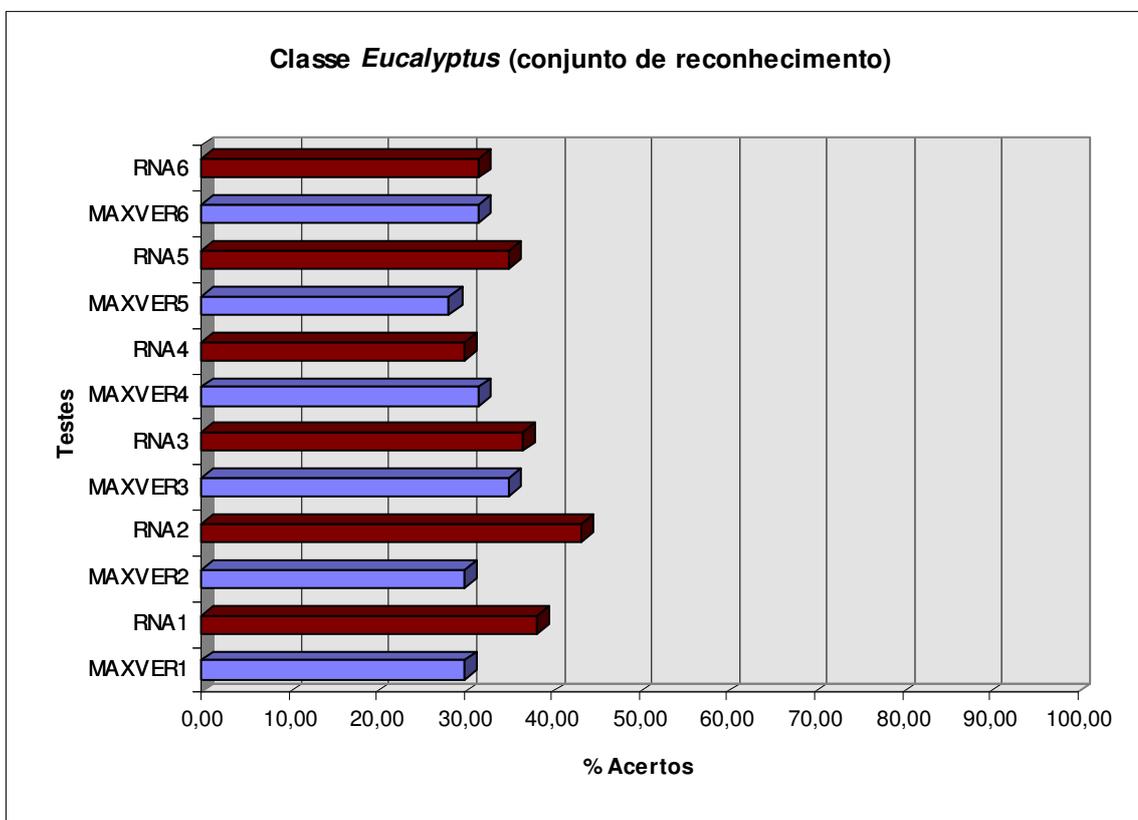


FIGURA 6.25 - Acurácia obtida para a classe *Eucalyptus* (conjunto de reconhecimento)

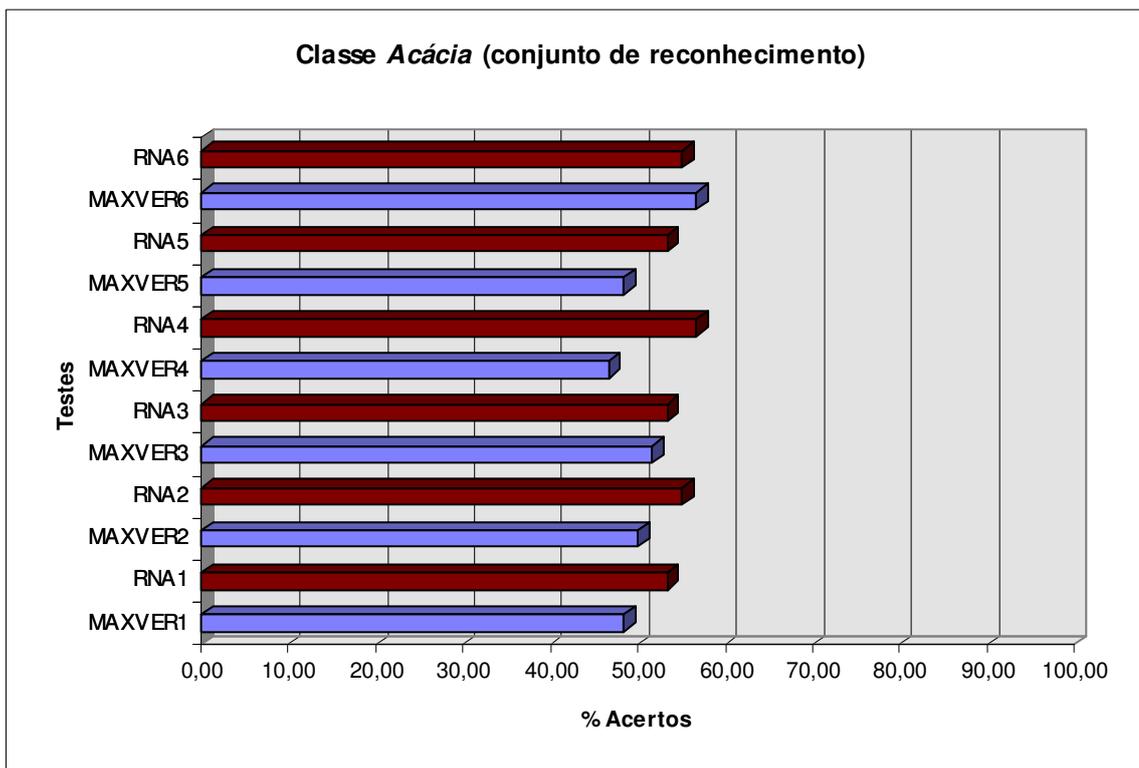


FIGURA 6.26 - Acurácia obtida para a classe *Acácia* (conjunto de reconhecimento)

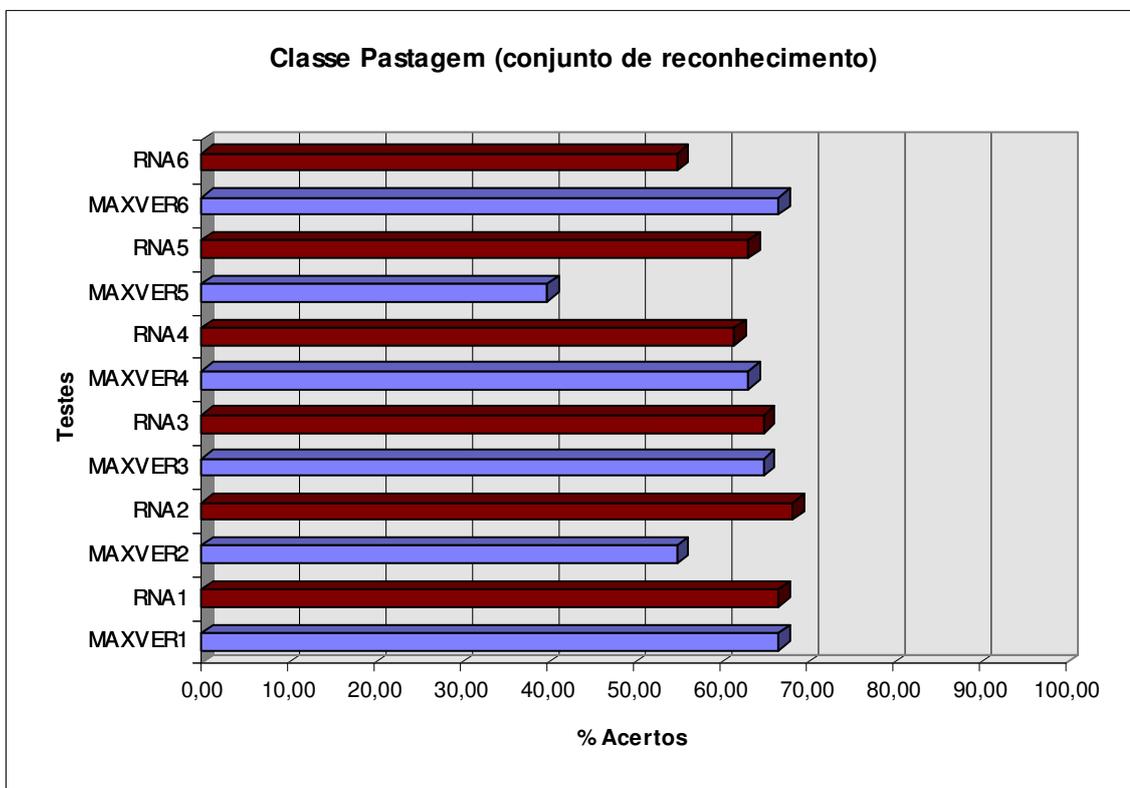


FIGURA 6.27 - Acurácia obtida para a classe *Pastagem* (conjunto de reconhecimento)

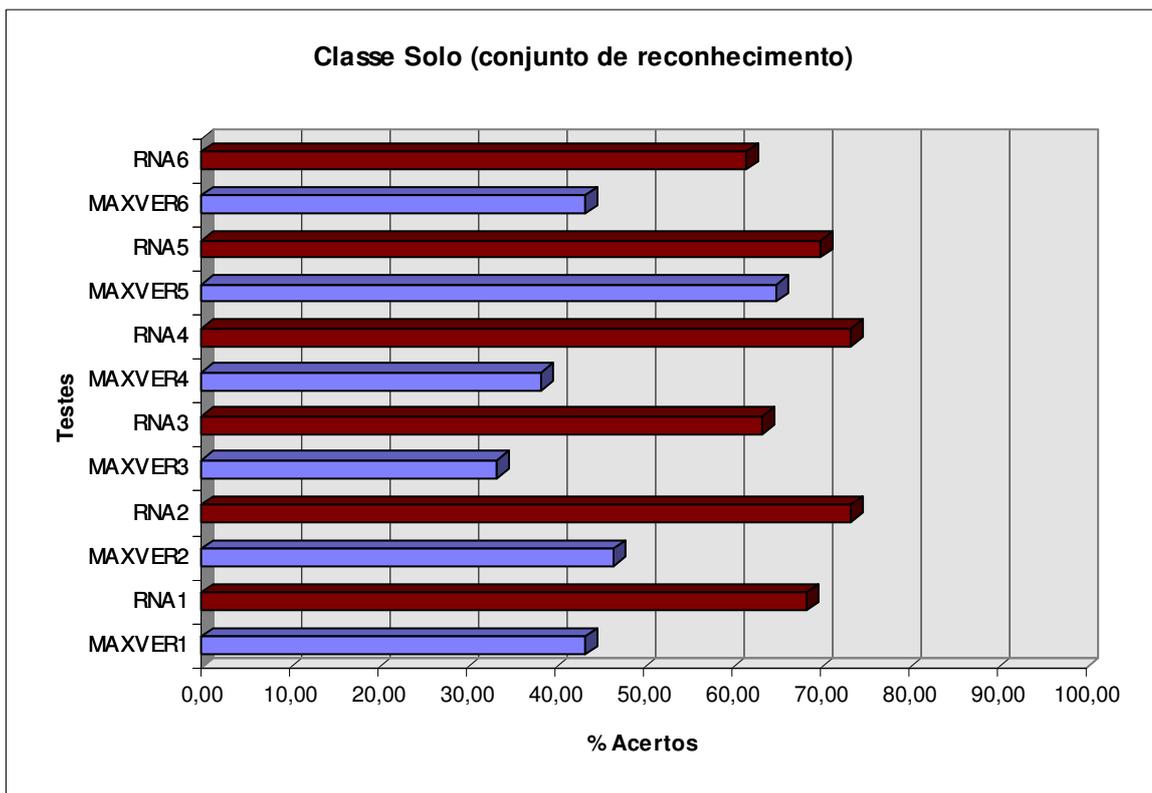


FIGURA 6.28 - Acurácia obtida para a classe Solo (conjunto de reconhecimento)

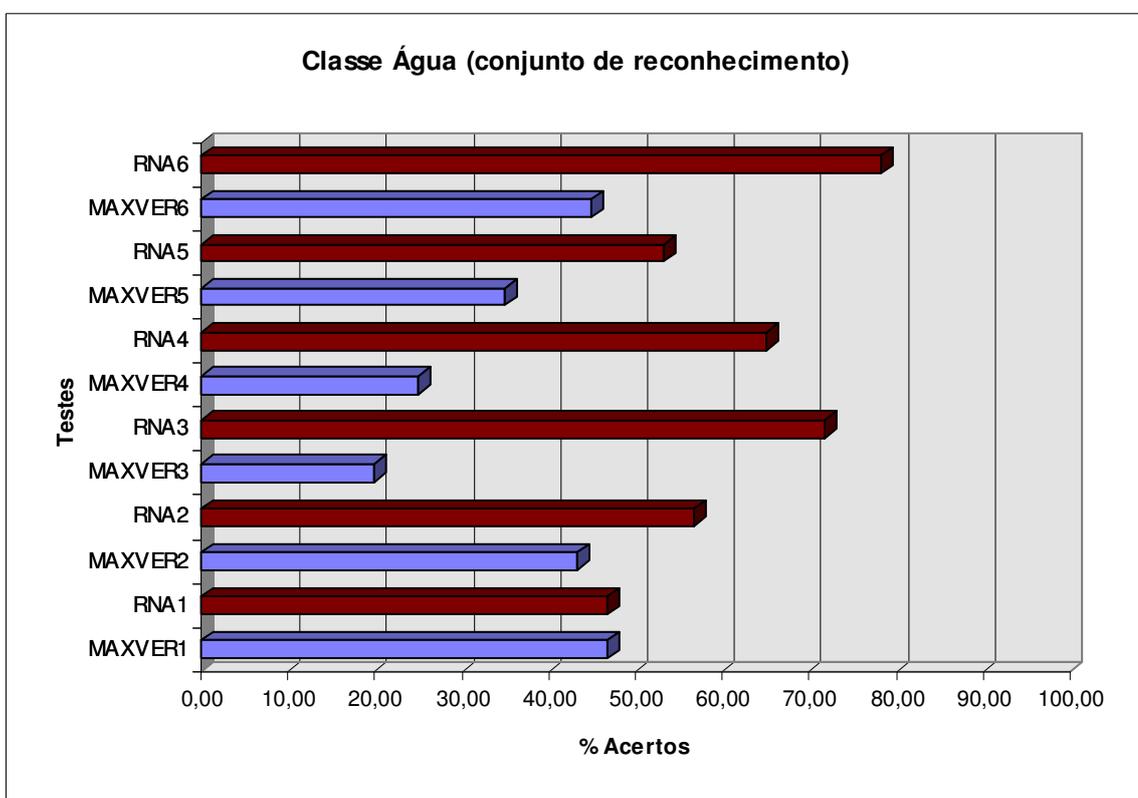


FIGURA 6.29 - Acurácia obtida para a classe Água (conjunto de reconhecimento)

TABELA XXIII - Teste 01 (bandas 123457). Conjunto de treinamento

H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Nativa				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Nativa				
	MAXVER	RNA		
Acertos	191	197	388	$\chi_{\text{calc}} = 1.09$
Erros	21	15	36	$\chi_{\text{tab}} = 3.84$
	212	212	424	Aceita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Eucalyptus				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Eucalyptus				
	MAXVER	RNA		
Acertos	210	216	426	$\chi_{\text{calc}} = 3.08$
Erros	9	3	12	$\chi_{\text{tab}} = 3.84$
	219	219	438	Não aplicável (uma célula com menos de 5 Observações)
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Acácia				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Acácia				
	MAXVER	RNA		
Acertos	203	210	413	$\chi_{\text{calc}} = 4.57$
Erros	9	2	11	$\chi_{\text{tab}} = 3.84$
	212	212	424	Não aplicável
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Pastagem				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Pastagem				
	MAXVER	RNA		
Acertos	184	210	394	$\chi_{\text{calc}} = 24.25$
Erros	28	2	30	$\chi_{\text{tab}} = 3.84$
	212	212	424	Não aplicável
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Solo				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Solo				
	MAXVER	RNA		
Acertos	63	69	132	$\chi_{\text{calc}} = 6.27$
Erros	6	0	6	$\chi_{\text{tab}} = 3.84$
	69	69	138	Não aplicável
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Água				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Água				
	MAXVER	RNA		
Acertos	118	129	247	$\chi_{\text{calc}} = 11.49$
Erros	11	0	11	$\chi_{\text{tab}} = 3.84$
	129	129	258	Não aplicável

TABELA XXIV - Teste 02 (bandas 12345). Conjunto de treinamento

H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Nativa				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Nativa				
	MAXVER	RNA		
Acertos	164	188	352	$\chi_{\text{calc}} = 9.64$
Erros	48	24	72	$\chi_{\text{tab}} = 3.84$
	212	212	424	Rejeita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Eucalyptus				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Eucalyptus				
	MAXVER	RNA		
Acertos	210	213	423	$\chi_{\text{calc}} = 0.62$
Erros	9	6	15	$\chi_{\text{tab}} = 3.84$
	219	219	438	Aceita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Acácia				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Acácia				
	MAXVER	RNA		
Acertos	198	208	406	$\chi_{\text{calc}} = 5.80$
Erros	14	4	18	$\chi_{\text{tab}} = 3.84$
	212	212	424	Não aplicável
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Pastagem				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Pastagem				
	MAXVER	RNA		
Acertos	125	208	333	$\chi_{\text{calc}} = 96.39$
Erros	87	4	91	$\chi_{\text{tab}} = 3.84$
	212	212	424	Não aplicável
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Solo				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Solo				
	MAXVER	RNA		
Acertos	40	69	109	$\chi_{\text{calc}} = 36.72$
Erros	29	0	29	$\chi_{\text{tab}} = 3.84$
	69	69	138	Não aplicável
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Água				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Água				
	MAXVER	RNA		
Acertos	116	129	245	$\chi_{\text{calc}} = 13.69$
Erros	13	0	13	$\chi_{\text{tab}} = 3.84$
	129	129	258	Não aplicável

TABELA XXV - Teste 03 (bandas 13457). Conjunto de treinamento

H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Nativa				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Nativa				
	MAXVER	RNA		
Acertos	182	198	380	$\chi_{\text{calc}} = 6.49$
Erros	30	14	44	$\chi_{\text{tab}} = 3.84$
	212	212	424	Rejeita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Eucalyptus				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Eucalyptus				
	MAXVER	RNA		
Acertos	209	212	421	$\chi_{\text{calc}} = 0.55$
Erros	10	7	17	$\chi_{\text{tab}} = 3.84$
	219	219	438	Aceita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Acácia				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Acácia				
	MAXVER	RNA		
Acertos	198	209	407	$\chi_{\text{calc}} = 7.41$
Erros	14	3	17	$\chi_{\text{tab}} = 3.84$
	212	212	424	Não aplicável
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Pastagem				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Pastagem				
	MAXVER	RNA		
Acertos	171	209	380	$\chi_{\text{calc}} = 36.62$
Erros	41	3	44	$\chi_{\text{tab}} = 3.84$
	212	212	424	Não aplicável
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Solo				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Solo				
	MAXVER	RNA		
Acertos	45	69	114	$\chi_{\text{calc}} = 29.05$
Erros	24	0	24	$\chi_{\text{tab}} = 3.84$
	69	69	138	Não aplicável
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Água				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Água				
	MAXVER	RNA		
Acertos	106	129	235	$\chi_{\text{calc}} = 25.25$
Erros	23	0	23	$\chi_{\text{tab}} = 3.84$
	129	129	258	Não aplicável

TABELA XXVI - Teste 04 (bandas 12457). Conjunto de treinamento

H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Nativa				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Nativa				
	MAXVER	RNA		
Acertos	179	178	357	$\chi_{\text{calc}} = 0.02$
Erros	33	34	67	$\chi_{\text{tab}} = 3.84$
	212	212	424	Aceita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Eucalyptus				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Eucalyptus				
	MAXVER	RNA		
Acertos	212	210	422	$\chi_{\text{calc}} = 0.26$
Erros	7	9	16	$\chi_{\text{tab}} = 3.84$
	219	219	438	Aceita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Acácia				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Acácia				
	MAXVER	RNA		
Acertos	196	211	407	$\chi_{\text{calc}} = 13.79$
Erros	16	1	17	$\chi_{\text{tab}} = 3.84$
	212	212	424	Não aplicável
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Pastagem				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Pastagem				
	MAXVER	RNA		
Acertos	181	196	377	$\chi_{\text{calc}} = 5.38$
Erros	31	16	47	$\chi_{\text{tab}} = 3.84$
	212	212	424	Rejeita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Solo				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Solo				
	MAXVER	RNA		
Acertos	45	67	112	$\chi_{\text{calc}} = 22.94$
Erros	24	2	26	$\chi_{\text{tab}} = 3.84$
	69	69	138	Não aplicável
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Água				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Água				
	MAXVER	RNA		
Acertos	105	129	234	$\chi_{\text{calc}} = 26.46$
Erros	24	0	24	$\chi_{\text{tab}} = 3.84$
	129	129	258	Não aplicável

TABELA XXVII - Teste 05 (bandas 12347). Conjunto de treinamento

<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Nativa H₁: existe diferença significativa entre ambos os métodos para a classe Nativa</p>				
	MAXVER	RNA		
Acertos	176	194	370	$\chi_{\text{calc}} = 6.88$ $\chi_{\text{tab}} = 3.84$ Rejeita H₀
Erros	36	18	54	
	212	212	424	
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Eucalyptus H₁: existe diferença significativa entre ambos os métodos para a classe Eucalyptus</p>				
	MAXVER	RNA		
Acertos	210	213	423	$\chi_{\text{calc}} = 0.62$ $\chi_{\text{tab}} = 3.84$ Aceita H₀
Erros	9	6	15	
	219	219	438	
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Acácia H₁: existe diferença significativa entre ambos os métodos para a classe Acácia</p>				
	MAXVER	RNA		
Acertos	201	209	410	$\chi_{\text{calc}} = 4.73$ $\chi_{\text{tab}} = 3.84$ Não aplicável
Erros	11	3	14	
	212	212	424	
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Pastagem H₁: existe diferença significativa entre ambos os métodos para a classe Pastagem</p>				
	MAXVER	RNA		
Acertos	103	205	308	$\chi_{\text{calc}} = 123.47$ $\chi_{\text{tab}} = 3.84$ Rejeita H₀
Erros	109	7	116	
	212	212	424	
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Solo H₁: existe diferença significativa entre ambos os métodos para a classe Solo</p>				
	MAXVER	RNA		
Acertos	42	69	111	$\chi_{\text{calc}} = 33.57$ $\chi_{\text{tab}} = 3.84$ Não aplicável
Erros	27	0	27	
	69	69	138	
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Água H₁: existe diferença significativa entre ambos os métodos para a classe Água</p>				
	MAXVER	RNA		
Acertos	114	129	243	$\chi_{\text{calc}} = 15.93$ $\chi_{\text{tab}} = 3.84$ Não aplicável
Erros	15	0	15	
	129	129	258	

TABELA XXVIII - Teste 06 (bandas 23457). Conjunto de treinamento

<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Nativa H₁: existe diferença significativa entre ambos os métodos para a classe Nativa</p>				
	MAXVER	RNA		
Acertos	188	196	384	$\chi_{\text{calc}} = 1.77$
Erros	24	16	40	$\chi_{\text{tab}} = 3.84$
	212	212	424	Aceita H₀
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Eucalyptus H₁: existe diferença significativa entre ambos os métodos para a classe Eucalyptus</p>				
	MAXVER	RNA		
Acertos	212	214	426	$\chi_{\text{calc}} = 0.34$
Erros	7	5	12	$\chi_{\text{tab}} = 3.84$
	219	219	438	Aceita H₀
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Acácia H₁: existe diferença significativa entre ambos os métodos para a classe Acácia</p>				
	MAXVER	RNA		
Acertos	205	210	415	$\chi_{\text{calc}} = 2.84$
Erros	7	2	9	$\chi_{\text{tab}} = 3.84$
	212	212	424	Não aplicável
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Pastagem H₁: existe diferença significativa entre ambos os métodos para a classe Pastagem</p>				
	MAXVER	RNA		
Acertos	194	204	398	$\chi_{\text{calc}} = 4.10$
Erros	18	8	26	$\chi_{\text{tab}} = 3.84$
	212	212	424	Rejeita H₀
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Solo H₁: existe diferença significativa entre ambos os métodos para a classe Solo</p>				
	MAXVER	RNA		
Acertos	57	68	125	$\chi_{\text{calc}} = 10.28$
Erros	12	1	13	$\chi_{\text{tab}} = 3.84$
	69	69	138	Não aplicável
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Água H₁: existe diferença significativa entre ambos os métodos para a classe Água</p>				
	MAXVER	RNA		
Acertos	117	129	246	$\chi_{\text{calc}} = 12.59$
Erros	12	0	12	$\chi_{\text{tab}} = 3.84$
	129	129	258	Não aplicável

TABELA XXIX - Teste 01 (bandas 123457). Conjunto de reconhecimento

<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Nativa H_1: existe diferença significativa entre ambos os métodos para a classe Nativa</p>			
	MAXVER	RNA	
Acertos	34	34	68
Erros	26	26	52
	60	60	120
			<p>$\chi_{\text{calc}} = 0.00$ $\chi_{\text{tab}} = 3.84$ Aceita H_0</p>
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Eucalyptus H_1: existe diferença significativa entre ambos os métodos para a classe Eucalyptus</p>			
	MAXVER	RNA	
Acertos	18	23	41
Erros	42	37	79
	60	60	120
			<p>$\chi_{\text{calc}} = 0.93$ $\chi_{\text{tab}} = 3.84$ Aceita H_0</p>
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Acácia H_1: existe diferença significativa entre ambos os métodos para a classe Acácia</p>			
	MAXVER	RNA	
Acertos	29	32	61
Erros	31	28	59
	60	60	120
			<p>$\chi_{\text{calc}} = 0.30$ $\chi_{\text{tab}} = 3.84$ Aceita H_0</p>
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Pastagem H_1: existe diferença significativa entre ambos os métodos para a classe Pastagem</p>			
	MAXVER	RNA	
Acertos	40	40	80
Erros	20	20	40
	60	60	120
			<p>$\chi_{\text{calc}} = 0.00$ $\chi_{\text{tab}} = 3.84$ Aceita H_0</p>
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Solo H_1: existe diferença significativa entre ambos os métodos para a classe Solo</p>			
	MAXVER	RNA	
Acertos	26	41	67
Erros	34	19	53
	60	60	120
			<p>$\chi_{\text{calc}} = 7.60$ $\chi_{\text{tab}} = 3.84$ Rejeita H_0</p>
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Água H_1: existe diferença significativa entre ambos os métodos para a classe Água</p>			
	MAXVER	RNA	
Acertos	28	28	56
Erros	32	32	64
	60	60	120
			<p>$\chi_{\text{calc}} = 0.00$ $\chi_{\text{tab}} = 3.84$ Aceita H_0</p>

TABELA XXX - Teste 02 (bandas 12345). Conjunto de reconhecimento

<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Nativa H_1: existe diferença significativa entre ambos os métodos para a classe Nativa</p>				
	MAXVER	RNA		
Acertos	30	31	61	$\chi_{calc} = 0.03$
Erros	30	29	59	$\chi_{tab} = 3.84$
	60	60	120	Aceita H_0
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe <i>Eucalyptus</i> H_1: existe diferença significativa entre ambos os métodos para a classe <i>Eucalyptus</i></p>				
	MAXVER	RNA		
Acertos	18	26	44	$\chi_{calc} = 2.30$
Erros	42	34	76	$\chi_{tab} = 3.84$
	60	60	120	Aceita H_0
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe <i>Acácia</i> H_1: existe diferença significativa entre ambos os métodos para a classe <i>Acácia</i></p>				
	MAXVER	RNA		
Acertos	30	33	63	$\chi_{calc} = 0.30$
Erros	30	27	57	$\chi_{tab} = 3.84$
	60	60	120	Aceita H_0
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Pastagem H_1: existe diferença significativa entre ambos os métodos para a classe Pastagem</p>				
	MAXVER	RNA		
Acertos	33	41	74	$\chi_{calc} = 2.26$
Erros	27	19	46	$\chi_{tab} = 3.84$
	60	60	120	Aceita H_0
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Solo H_1: existe diferença significativa entre ambos os métodos para a classe Solo</p>				
	MAXVER	RNA		
Acertos	28	44	72	$\chi_{calc} = 8.89$
Erros	32	16	48	$\chi_{tab} = 3.84$
	60	60	120	Rejeita H_0
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe <i>Água</i> H_1: existe diferença significativa entre ambos os métodos para a classe <i>Água</i></p>				
	MAXVER	RNA		
Acertos	26	34	60	$\chi_{calc} = 2.13$
Erros	34	26	60	$\chi_{tab} = 3.84$
	60	60	120	Aceita H_0

TABELA XXXI - Teste 03 (bandas 13457). Conjunto de reconhecimento

H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Nativa				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Nativa				
	MAXVER	RNA		
Acertos	31	38	69	$\chi_{\text{calc}} = 1.67$
Erros	29	22	51	$\chi_{\text{tab}} = 3.84$
	60	60	120	Aceita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Eucalyptus				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Eucalyptus				
	MAXVER	RNA		
Acertos	21	22	43	$\chi_{\text{calc}} = 0.04$
Erros	39	38	77	$\chi_{\text{tab}} = 3.84$
	60	60	120	Aceita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Acácia				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Acácia				
	MAXVER	RNA		
Acertos	31	32	63	$\chi_{\text{calc}} = 0.03$
Erros	29	28	57	$\chi_{\text{tab}} = 3.84$
	60	60	120	Aceita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Pastagem				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Pastagem				
	MAXVER	RNA		
Acertos	39	39	78	$\chi_{\text{calc}} = 0.00$
Erros	21	21	42	$\chi_{\text{tab}} = 3.84$
	60	60	120	Aceita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Solo				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Solo				
	MAXVER	RNA		
Acertos	20	38	58	$\chi_{\text{calc}} = 10.81$
Erros	40	22	62	$\chi_{\text{tab}} = 3.84$
	60	60	120	Rejeita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Água				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Água				
	MAXVER	RNA		
Acertos	12	43	55	$\chi_{\text{calc}} = 32.26$
Erros	48	17	65	$\chi_{\text{tab}} = 3.84$
	60	60	120	Rejeita H₀

TABELA XXXII - Teste 04 (bandas 12457). Conjunto de reconhecimento

H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Nativa				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Nativa				
	MAXVER	RNA		
Acertos	35	36	71	$\chi_{\text{calc}} = 0.03$
Erros	25	24	49	$\chi_{\text{tab}} = 3.84$
	60	60	120	Aceita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Eucalyptus				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Eucalyptus				
	MAXVER	RNA		
Acertos	19	18	37	$\chi_{\text{calc}} = 0.04$
Erros	41	42	83	$\chi_{\text{tab}} = 3.84$
	60	60	120	Aceita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Acácia				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Acácia				
	MAXVER	RNA		
Acertos	28	34	62	$\chi_{\text{calc}} = 1.20$
Erros	32	26	58	$\chi_{\text{tab}} = 3.84$
	60	60	120	Aceita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Pastagem				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Pastagem				
	MAXVER	RNA		
Acertos	38	37	75	$\chi_{\text{calc}} = 0.04$
Erros	22	23	45	$\chi_{\text{tab}} = 3.84$
	60	60	120	Aceita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Solo				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Solo				
	MAXVER	RNA		
Acertos	23	44	67	$\chi_{\text{calc}} = 14.90$
Erros	37	16	53	$\chi_{\text{tab}} = 3.84$
	60	60	120	Rejeita H₀
H ₀ : NÃO existe diferença significativa entre ambos os métodos para a classe Água				
H ₁ : existe diferença significativa entre ambos os métodos para a classe Água				
	MAXVER	RNA		
Acertos	15	39	54	$\chi_{\text{calc}} = 19.39$
Erros	45	21	66	$\chi_{\text{tab}} = 3.84$
	60	60	120	Rejeita H₀

TABELA XXXIII - Teste 05 (bandas 12347). Conjunto de reconhecimento

<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Nativa H_1: existe diferença significativa entre ambos os métodos para a classe Nativa</p>				
	MAXVER	RNA		
Acertos	28	32	60	$\chi_{calc} = 0.53$
Erros	32	28	60	$\chi_{tab} = 3.84$
	60	60	120	Aceita H_0
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Eucalyptus H_1: existe diferença significativa entre ambos os métodos para a classe Eucalyptus</p>				
	MAXVER	RNA		
Acertos	17	21	38	$\chi_{calc} = 0.62$
Erros	43	39	82	$\chi_{tab} = 3.84$
	60	60	120	Aceita H_0
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Acácia H_1: existe diferença significativa entre ambos os métodos para a classe Acácia</p>				
	MAXVER	RNA		
Acertos	29	32	61	$\chi_{calc} = 0.30$
Erros	31	28	59	$\chi_{tab} = 3.84$
	60	60	120	Aceita H_0
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Pastagem H_1: existe diferença significativa entre ambos os métodos para a classe Pastagem</p>				
	MAXVER	RNA		
Acertos	24	38	62	$\chi_{calc} = 6.54$
Erros	36	22	58	$\chi_{tab} = 3.84$
	60	60	120	Rejeita H_0
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Solo H_1: existe diferença significativa entre ambos os métodos para a classe Solo</p>				
	MAXVER	RNA		
Acertos	39	42	81	$\chi_{calc} = 0.34$
Erros	21	18	39	$\chi_{tab} = 3.84$
	60	60	120	Aceita H_0
<p>H_0: NÃO existe diferença significativa entre ambos os métodos para a classe Água H_1: existe diferença significativa entre ambos os métodos para a classe Água</p>				
	MAXVER	RNA		
Acertos	21	32	53	$\chi_{calc} = 4.09$
Erros	39	28	67	$\chi_{tab} = 3.84$
	60	60	120	Aceita H_0

TABELA XXXIV - Teste 06 (bandas 23457). Conjunto de reconhecimento

<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Nativa H₁: existe diferença significativa entre ambos os métodos para a classe Nativa</p>				
	MAXVER	RNA		
Acertos	40	37	77	$\chi_{\text{calc}} = 0.33$
Erros	20	23	43	$\chi_{\text{tab}} = 3.84$
	60	60	120	Aceita H₀
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Eucalyptus H₁: existe diferença significativa entre ambos os métodos para a classe Eucalyptus</p>				
	MAXVER	RNA		
Acertos	19	19	38	$\chi_{\text{calc}} = 0.00$
Erros	41	41	82	$\chi_{\text{tab}} = 3.84$
	60	60	120	Aceita H₀
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Acácia H₁: existe diferença significativa entre ambos os métodos para a classe Acácia</p>				
	MAXVER	RNA		
Acertos	34	33	67	$\chi_{\text{calc}} = 0.03$
Erros	26	27	53	$\chi_{\text{tab}} = 3.84$
	60	60	120	Aceita H₀
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Pastagem H₁: existe diferença significativa entre ambos os métodos para a classe Pastagem</p>				
	MAXVER	RNA		
Acertos	40	33	73	$\chi_{\text{calc}} = 1.71$
Erros	20	27	47	$\chi_{\text{tab}} = 3.84$
	60	60	120	Aceita H₀
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Solo H₁: existe diferença significativa entre ambos os métodos para a classe Solo</p>				
	MAXVER	RNA		
Acertos	26	37	63	$\chi_{\text{calc}} = 4.04$
Erros	34	23	57	$\chi_{\text{tab}} = 3.84$
	60	60	120	Rejeita H₀
<p>H₀: NÃO existe diferença significativa entre ambos os métodos para a classe Água H₁: existe diferença significativa entre ambos os métodos para a classe Água</p>				
	MAXVER	RNA		
Acertos	27	47	74	$\chi_{\text{calc}} = 14.10$
Erros	33	13	46	$\chi_{\text{tab}} = 3.84$
	60	60	120	Rejeita H₀

7 DISCUSSÃO

Conforme as Figuras de 6.18 a 6.23 e as Tabelas de XXIII a XXVIII, apresentadas no capítulo anterior, é possível afirmar, para o conjunto de treinamento e para a área de estudo considerada, que:

- A Rede Neural Artificial Multinível com *BackPropagation* apresentou uma acurácia superior a 80% para todas as seis classes consideradas (Nativa, *Eucalyptus*, *Acácia*, Pastagem, Solo Exposto e Água) e para todos os seis testes realizados. Entretanto, o método de Máxima Verossimilhança Gaussiana apresentou, em alguns casos, uma acurácia inferior a 80% (é o caso do teste 02 para a classe Nativa, dos testes 02 e 05 para a classe Pastagem e dos testes 02, 03, 04 e 05 para a classe Solo);
- Não houve diferença significativa, ao nível de significância de 5%, para a classe *Eucalyptus*, entre ambos os métodos, em todos os testes, sendo a acurácia para esta classe superior a 95%;
- Para a classe Nativa, a Rede Neural Artificial Multinível com *BackPropagation* apresentou valores de acurácia (acima de 83%) superiores ao método tradicional para quase todos os testes, com exceção do teste 04 (bandas 12457). Porém, a diferença entre ambos os classificadores só é significativa, ao nível de 5%, para os testes 02 (bandas 12345), 03 (bandas 13457) e 05 (bandas 12347), onde a Rede Neural apresentou um melhor desempenho;
- Para a espécie *Acácia*, a Rede Neural Artificial Multinível com *BackPropagation* apresentou valores de acurácia mais elevados do que o método de Máxima Verossimilhança Gaussiana (acima de 98%). Houveram diferenças significativas, ao nível de 5%, entre ambos os métodos, para todos os testes, com exceção do teste 06 (bandas 23457);
- Para Pastagem a Rede Neural Artificial Multinível com *BackPropagation* apresentou diferenças significativas, ao nível de 5%, em relação ao método tradicional em todos os testes. Enquanto que a Rede Neural apresentou uma acurácia entre 92 e 99,06%, para esta classe, o método de Máxima Verossimilhança Gaussiana obteve uma

acurácia entre 48 e 91,51%. Salienta-se que o teste 05 (bandas 12347), do método tradicional, obteve uma acurácia inferior a 50%. E, este resultado é crítico, pois o método não conseguiu reconhecer corretamente a metade dos *pixels* de Pastagem que foram utilizados em seu próprio treinamento;

- Similarmente, para as classes Solo Exposto e Água, houve diferenças significativas, ao nível de 5%, para todos os testes, entre ambos os métodos. A Rede Neural Artificial Multinível com *BackPropagation* chegou a obter 100% de acurácia para a classe Água, enquanto que o método de Máxima Verossimilhança Gaussiana obteve uma acurácia entre 81 e 91,47%, dependendo do teste. Já para a classe Solo Exposto, a Rede Neural alcançou 100% de acurácia (com exceção dos testes 04 e 06, cuja acurácia foi de 97,10 e 98,55%, respectivamente). Já o método de Máxima Verossimilhança Gaussiana obteve uma acurácia de 57,97% para o teste 02 (bandas 12345) e 91,30% para o teste 01 (bandas 123457). Os demais testes apresentaram uma acurácia dentro deste intervalo (57,97-91,30%);

Conforme as Figuras de 6.24 a 6.29 e as Tabelas de XXIX a XXXIV é possível afirmar, para o conjunto de reconhecimento e para a área de estudo considerada, que:

- Ambos os classificadores supervisionados apresentaram uma acurácia inferior a 70%, para as classes Nativa, *Eucalyptus*, *Acácia* e Pastagem, em todos os testes. Entretanto, para as classes Solo e Água, apenas, a Rede Neural Artificial Multinível com *BackPropagation* obteve uma acurácia superior a 70% (sendo 73,33%, para os testes 02 e 04, da classe Solo e, 71,67 e 78,33%, para os testes 03 e 06, respectivamente, da classe Água);
- Para a classe *Eucalyptus* não houve diferença significativa, ao nível de 5%, entre ambos os métodos, para todos os testes. E, apesar da Rede Neural Artificial Multinível com *BackPropagation* apresentar valores superiores de acurácia em relação ao método tradicional, estes foram inferiores a 45%, ou seja, nem a metade dos *pixels* de reconhecimento foram corretamente classificados;

- Para a Mata Nativa, não houve diferença significativa entre os métodos, ao nível de 5%, em todos os testes. Entretanto, com exceção dos testes 01 (bandas 123457) e 06 (bandas 23457), a Rede Neural Artificial Multinível com *BackPropagation* apresentou um melhor desempenho (embora não significativo) do que o método de Máxima Verossimilhança Gaussiana;
- Similarmente, para a classe *Acácia*, não houve diferença significativa entre os métodos, ao nível de 5%, em todos os testes. Neste caso, apenas para o teste 06 (bandas 23457), o método de Máxima Verossimilhança Gaussiana apresentou uma acurácia superior (56,67%) a Rede Neural (que obteve uma acurácia de 55%), embora não significativa;
- Para a classe Pastagem, houve diferença significativa entre os métodos, somente, para o teste 05 (bandas 12347). Para os testes 04 (bandas 12457) e 06 (bandas 23457), o método tradicional obteve valores superiores de acurácia em relação a Rede Neural, embora não significativos. Para os testes 04 e 06, o método de Máxima Verossimilhança Gaussiana obteve uma acurácia de 63,33 e 66,67%, respectivamente, enquanto que a Rede Neural mostrou uma acurácia de 61,67 e 55%;
- Já para as classes Solo e Água, a Rede Neural Artificial Multinível com *BackPropagation* apresentou valores superiores de acurácia (entre 61 e 73,33% para Solo Exposto e, entre 46 e 78,33% para Água). A diferença entre ambos os métodos é significativa, ao nível de 5%, para a classe Solo em todos os testes, com exceção do teste 05 (bandas 12347). Já para a classe Água, houve diferença significativa, ao nível de 5%, somente, para os testes 03 (bandas 13457), 04 (bandas 12457) e 06 (bandas 23457). Entretanto, para esta classe, o método de Máxima Verossimilhança Gaussiana obteve valores de acurácia inferiores a 46,67%, em todos os testes, não classificando corretamente a metade dos *pixels* de reconhecimento.

A redução dos níveis de acurácia do conjunto de reconhecimento em relação ao conjunto de treinamento era previsível, pois é mais difícil aos classificadores

classificar corretamente *pixels* desconhecidos do que aqueles utilizados no seu próprio treinamento.

Com relação às amostras selecionadas para treinamento, pode-se dizer que as classes *Eucalyptus*, *Nativa* e *Acácia* apresentaram, em todas as bandas, um histograma com distribuição unimodal conforme pode ser observado no Anexo 09. Porém, as classes Pastagem (bandas 05 e 07), Água (bandas 02 e 03) e Solo Exposto (banda 05) exibem histogramas fortemente bimodais. Desta forma, é provável que os elevados valores de acurácia obtidos pela Rede Neural Artificial Multinível com *BackPropagation*, para estas classes, esteja na capacidade que a rede possui de generalizar o seu conhecimento de maneira a identificar corretamente determinados *pixels* mesmo que estes apresentem variações espectrais em função de fatores externos. Como exemplo, a Rede Neural foi capaz de atribuir à classe Pastagem, tanto áreas de pasto secas quanto úmidas, já que esta diferenciação não era desejada. Da mesma forma, águas mais sujas não deixaram de ser reconhecidas pela rede como pertencentes à classe Água.

Já o método de Máxima Verossimilhança Gaussiana obteve valores significativamente inferiores de acurácia, para estas classes (Pastagem, Solo Exposto e Água) e para todos os testes, mostrando-se mais sensível a variações espectrais, mesmo que isto não seja desejado. Conforme JENSEN (1986), este método assume que os dados são normalmente distribuídos. E, como neste caso, as amostras de treinamento, para estas classes, não se apresentaram desta maneira, os resultados obtidos foram pouco satisfatórios.

Para o conjunto de reconhecimento, dos 18 testes realizados, envolvendo as três classes: Pastagem, Solo Exposto e Água, a Rede Neural obteve valor superior de acurácia em 13 deles. Destes, somente nove apresentaram valores significativamente mais elevados do que o método tradicional.

Em termos de tempo de processamento, a Rede Neural Artificial Multinível com *BackPropagation* apresenta um custo computacional consideravelmente mais elevado do que o método de Máxima Verossimilhança Gaussiana, durante a etapa de treinamento. Utilizando-se um *Pentium* de 166 *Mhz* e 32 MB de memória RAM, a Rede Neural demorou cerca de 8 horas para aprender adequadamente os 1.053 *pixels* de treinamento, enquanto que o método tradicional demorou de 1 a 2 minutos para extrair os parâmetros estatísticos a partir destes *pixels*. Para a fase de reconhecimento, ambos

os métodos classificaram o mosaico composto pelas 12 *imagettes* em alguns poucos minutos.

Com relação aos *clusterizadores* (*Kohonen* e Histograma Tridimensional) é possível observar que:

- O método do Histograma Tridimensional é limitado quanto ao número de bandas que podem ser utilizadas na *clusterização*. Neste caso, a dificuldade está em determinar qual o conjunto de três bandas que é o mais indicado para a aplicação em questão. Entretanto, para *Kohonen* foi possível utilizar todas as seis bandas, sendo que a única limitação está no *software* IRENE que permite o uso de até 10 bandas simultaneamente;
- Para o método do Histograma Tridimensional não existe uma relação entre a similaridade das classes e as cores a elas atribuídas, como ocorre com *Kohonen*;
- A *clusterização* das áreas amostrais por *Kohonen*, utilizando somente as bandas 345 apresentou resultados insatisfatórios, visto que não foi possível distinguir entre Água, *Acácia* e *Eucalyptus*. Para este conjunto de bandas, visualmente, o método do Histograma Tridimensional apresentou um melhor resultado (Figuras 6.1 e 6.3). Porém, para *Kohonen*, resultados melhores foram obtidos pelo uso de um número maior de bandas e de neurônios (Figuras 6.4 e 6.5);
- A *clusterização* por *Kohonen* apresentada na Figura 6.4 (bandas 23457) parece, visualmente, ser melhor do que a exibida na Figura 6.5 (bandas 123457). No primeiro caso, a classe Água aparece na cor branca-acinzentada, não sendo confundida com nenhuma outra classe. A classe Pastagem aparece nas cores azul e verde, enquanto que a Mata Nativa aparece em tons de roxo. Já a classe *Acácia* aparece em tons misturados de amarelo e rosa claro, enquanto que a classe *Eucalyptus* aparece em tons rosados mais escuros. Apenas a classe Solo Exposto não aparece bem definida (na área amostral número 11) confundindo-se com a classe Pastagem. No segundo caso (Figura 6.5) há uma confusão entre as classes Água e *Acácia*, ambas aparecendo em tons esverdeados (sendo que a Água aparece em tons esverdeados mais escuros). Porém, supõe-se

que esta confusão ocorra em função da banda 1 que dentre as bandas utilizadas é a que apresenta uma maior interferência atmosférica, interferindo nos resultados da *clusterização*;

- Para o método do Histograma Tridimensional (Figuras 6.1 e 6.2), ambos os testes diferenciaram a água do Rio Jacuí, amostras número 05 e 11, da água do açude contido na amostra número 02. Além disto, observa-se uma confusão entre Pastagem, Solo Exposto e Água (do açude), sendo estes exibidos na cor preta, em alguns pontos.

8 CONCLUSÕES GERAIS E SUGESTÕES

Cumprindo com o compromisso da multidisciplinariedade, este trabalho, envolvendo as áreas de Sensoriamento Remoto, Engenharia Florestal e Inteligência Artificial, teve por fim:

- A verificação do uso de *clusterizadores* para a identificação das possíveis classes e subclasses existentes na área de estudo, sendo que os *clusterizadores* utilizados foram: uma Rede Neural Artificial conhecida por *Kohonen* e o método tradicional denominado Histograma Tridimensional;
- A comparação qualitativa e quantitativa entre o método de Máxima Verossimilhança Gaussiana e uma Rede Neural Artificial Multinível com *BackPropagation*. Esta comparação baseou-se na identificação de seis classes (Mata Nativa, *Eucalyptus*, *Acácia*, Pastagem, Solo Exposto e Água), em imagens multi-espectrais, do satélite LANDSAT 5 -TM, que cobrem a área de estudo.

Assim, após a interpretação e análise dos resultados obtidos é possível responder às duas questões propostas inicialmente: até que ponto os classificadores tradicionais são satisfatórios na identificação de alvos em imagens multi-espectrais? E, as Redes Neurais Artificiais podem vir a contribuir no aumento da acurácia em classificações digitais?

Em termos gerais, as Redes Neurais (*Kohonen* e RNA Multinível com *BackPropagation*) podem vir a contribuir no aumento da acurácia, se comparadas aos métodos tradicionais (Histograma Tridimensional e Máxima Verossimilhança Gaussiana), desde que as bandas utilizadas na classificação sejam devidamente escolhidas através de um método estatístico apropriado de seleção de bandas.

Entretanto, para a área de estudo considerada e ao nível de significância de 5%, nenhuma das espécies vegetais consideradas (*Eucalyptus*, *Acácia* e Nativa) apresentou diferença significativa de classificação entre ambos os métodos supervisionados (Máxima Verossimilhança Gaussiana e Rede Neural Multinível com *BackPropagation*), em todos os testes realizados com o conjunto de reconhecimento. Porém, na maior parte destes testes, a Rede Neural apresentou valores de acurácia superiores aos obtidos pelo método tradicional. Para as demais classes (Pastagem, Solo

Exposto e Água), em alguns casos, a Rede Neural apresentou valores de acurácia significativamente superiores ao método de Máxima Verossimilhança Gaussiana na classificação de *pixels* desconhecidos.

Para os *clusterizadores* utilizados (*Kohonen* e Histograma Tridimensional) salienta-se, conforme RICHARDS (1986), que os resultados gerados não são únicos, mas dependem dos parâmetros de *clusterização* escolhidos. Na prática, é necessário aplicar o algoritmo de *clusterização* várias vezes com diferentes parâmetros para gerar a segmentação desejada.

Para trabalhos futuros sugere-se:

1. A inclusão do algoritmo de *BackPropagation* ao sistema IRENE a fim de disponibilizá-lo a um grupo maior de usuários que desejem realizar outras pesquisas envolvendo os Mapas de *Kohonen* e/ou as Redes Neurais com *BackPropagation*;
2. A aplicação de rótulos às classes obtidas por ambos os *clusterizadores* (*Kohonen* e Histograma Tridimensional) realizando, assim, uma classificação não-supervisionada. Após este processo é possível que as diferenças entre os métodos tornem-se mais evidentes;
3. A realização de um novo teste com *Kohonen* considerando as bandas 345, porém utilizando um mapa com dimensão 6, para comparar com o método do Histograma Tridimensional;
4. A comparação de *Kohonen* com outros métodos de *clusterização*, tais como: *Clusterização* por Passagem Simples e *Clusterização* Hierárquica Aglomerativa;
5. A confecção de um mapa de referência para o mosaico composto pelas 12 *imagettes*. Este mapa poderia ser confeccionado, pelo *software AutoCad*, através da digitalização de cada uma das *imagettes*. Porém, neste caso, um cuidado especial deve ser tomado em relação às divisas entre classes. Este mapa poderia ser utilizado para comparar os resultados obtidos pelo método de Máxima Verossimilhança Gaussiana e pela Rede Neural Multinível com *BackPropagation*. Assim, seria

possível averiguar se a acurácia obtida aqui, para ambos os classificadores, sofre ou não grandes alterações em função de um número muito maior de pontos de teste para um conjunto de reconhecimento. Outra possibilidade seria comparar o mosaico de referência obtido pela digitalização das *imagettes* com o mosaico obtido pela classificação não-supervisionada sobre os resultados obtidos com *Kohonen*. Neste último caso seria possível verificar se o mosaico produzido por *Kohonen* pode ou não ser utilizado como um mapa de referência;

6. A incorporação às Redes Neurais de informações espaciais (tais como: textura e forma do arranjo de *pixels*) e/ou de Sistemas de Informação Geográfica (como altimetria, precipitação, entre outras), para averiguar sobre uma possível melhoria na classificação de imagens multi-espectrais.

Acredita-se que este trabalho pode servir como motivação e inspiração para novas pesquisas na área.

BIBLIOGRAFIA

- AN, P. et al. Digital Lithology Mapping from Airborne Geophysical and Remote Sensing Data in the Melville Peninsula, Northern Canada, Using a Neural Network Approach. **IEEE Remote Sens. Environ**, New York, v. 53, p.76-84, Jan., 1995.
- ASSUNÇÃO, G.V.; FORMAGGIO, A.R. **O Sensoriamento Remoto na Agricultura: Conceitos Básicos, Metodologia e Aplicações**. São José dos Campos: INPE, 1989. 217p.
- BALANIUK, R. **Modelos de Redes Neurais: Conceitos Básicos e Evolução Histórica**. Porto Alegre: CPGCC - UFRGS, 1989. 122p. (Trabalho Individual)
- BISCHOF, H et al. Multispectral Classification of Landsat - Images Using Neural Networks. **IEEE Trans. Geosci. Remote Sensing**, New York, v.30, n.3, p.482-490, May, 1992.
- CAMARGO, A. P. **Estão plantando um deserto ?** Porto Alegre: UFRGS, 1975.
- CRÓSTA, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto**. Campinas: IG-UNICAMP, 1992.
- DEPPE, F. **Applications of Remote Sensing and Geographic Information Systems for Management and Planning Forestry Resources in Southern Brazil**. Cranfield: Cranfield University-Silsoe College, 1995. 330p.
- EASTMAN, J. R. **Exercícios Tutoriais - IDRISI for Windows**. Porto Alegre: Centro de Recursos Idrisi, 1996. 109p.
- EMBRAPA-CNPQ. Zoneamento Ecológico para Plantios Florestais no Estado de Santa Catarina. **Documentos**, 21. Curitiba: Embrapa, 1988. 113p.
- ENGEL, P. M. Inteligência Artificial e Redes Neurais em Prospecção Ambiental e Sensoriamento Remoto. In: SIMPÓSIO DE APLICAÇÕES DA INFORMÁTICA EM BIOLOGIA, InfoBio'93, I, 1993, Campinas. **Anais ...** Campinas: [S.n.], 1993. p 24-25.
- FONTANA, D. C. **Utilização do Índice de Vegetação Global para o Monitoramento da Vegetação e Estimativa de Elementos Agrometeorológicos no Estado do RS**. Porto Alegre: CEPSSRM - UFRGS, 1995. (Tese de Doutorado).
- FREEMAN, J. A.; SKAPURA, D. M. **Neural Networks, Algorithms, Applications, and Programming Techniques**. New York: Addison Wesley, 1991.
- GOLFARI, L. **Fantasia e Realidades sobre Plantios de Eucaliptos**. Belo Horizonte: Centro de Pesquisa Florestal da Região Centro-Leste, 1975.

- HEERMANN, P. D.; KHAZENIE, N. Classification of Multispectral Remote Sensing Data Using a Back-Propagation Neural Network. **IEEE Trans. Geosci. Remote Sensing**. New York, v. 30, n.1, p.81-88, Jan.,1992.
- IBDF. **Inventário Florestal Nacional - Reflorestamento RS**. Brasília: IBDF, 1983. 182 p.
- JENSEN, J.R., **Introductory Digital Image Processing**. New Jersey: Prentice-Hall, 1986. 379p.
- KOHONEN, T. The Self-Organizing Map. **Proceedings...** New York: IEEE, v. 78, n.9, p.1464-80, Sep.,1990.
- KOHONEN, T., **Self-Organization and Associative Memory**. New York: Springer-Verlag, 1989. 312p.
- LAMPRECHT, H. **Silvicultura nos Trópicos: ecossistemas florestais e respectivas espécies arbóreas - Possibilidades e Métodos de Aproveitamento Sustentado**. Eschborn: [S.n.], 1990. 343p.
- LAPOLLI, E. et al., Classificação de Imagens Digitais: Comparação entre Vários Métodos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, VII, 1993, [S.l.]. **Anais ...** [S.l.:s.n], 1993. p 373-380.
- LINDMAN, C. A. M.; FERRI, M. G. **A Vegetação no RS**. São Paulo: [S.n.], 1974. 377p.
- MACHADO, R.J., Interpretação de Imagens de Satélite da Amazônia Usando Redes Neurais. In: SIMPÓSIO DE APLICAÇÕES DA INFORMÁTICA EM BIOLOGIA, InfoBio'93, I, 1993, Campinas. **Anais ...** Campinas: [S.n.], 1993. p.25-26.
- MATTOS, N. F. **Espécies conhecidas como “Acácia Negra”, cultivadas no Rio Grande do Sul**. Porto Alegre: Roessleria - IPRNR, 1980. p.67-79.
- MILIDIÚ, R. L. Fundamentos de Redes Neurais. In: CONGRESSO NACIONAL DE MATEMÁTICA APLICADA E COMPUTACIONAL, CNMAC, 18, Curitiba, **Minicurso...**, Curitiba: UFPR, 1995. 44p.
- NOVO, E. M. **Sensoriamento Remoto: Princípios e Aplicações**. São Paulo: Edgard Blucher, 1989. 308p.
- NUNES, R. V. **Uma Abordagem Neural para Tratamento de Imagens Multiespectrais**. Porto Alegre: CPGCC - UFRGS, 1995. 106p. (Trabalho Individual)
- REITZ, R. et al. **Projeto Madeira do Rio Grande do Sul**. Porto Alegre: Herbário Barbosa Rodrigues-SUDESUL-Sec. da Agricultura e Abastecimento, 1988. 525p.

- RICHARDS, J. A. **Remote Sensing Digital Image Analysis - An Introduction.** New York: Springer-Verlag, 1986.
- RUMELHART, D. et al. Learning Internal Representations by Error Propagation. **Parallel Distributed Processing: Explorations in the Microstructures of Cognition.** Cambridge: MIT Press, v.1, p.318-362,1986.
- SAMPAIO, A. D. **Os Eucaliptos no Brasil.** [S.l.:s.n.],1975.
- SEIBERT, M. G. F. **Neural Network Image Analysis for Environmental Protection.** 1992.
- SOCIEDADE BRASILEIRA DE SILVICULTURA. Austrália: a mãe do reflorestamento brasileiro. **Revista Silvicultura**, n.61, v.5-6, p.30-32, 1995.
- SOCIEDADE BRASILEIRA DE SILVICULTURA. Brasil Exporta Óleo Essencial de Eucalipto. **Revista Silvicultura**, n. 61, v.3-4, p.34, 1995.
- SPIEGEL, M. R. **Probabilidade e Estatística.** São Paulo: McGraw-Hill do Brasil, 1978. 518p.
- SWAIN, P. H.; DAVIS, S .M. **Remote Sensing: The Quantitative Approach.** New York: McGraw-Hill, 1978. 396p.
- TODT, V. et al. Uma comparação entre o Método de Máxima Verossimilhança Gaussiana e uma Rede Neural Artificial Multinível com BackPropagation na Classificação de Espécies Vegetais. In: WORKSHOP SOBRE ASPECTOS TEORICOS DE LA INTELIGENCIA ARTIFICIAL, 3er, 1996, San Luis. **Anais...** San Luis: [s.n.], 1996. p.657-669.
- VASCONCELOS, G. C. Redes Neurais e Reconhecimento de Padrões. In: SIMPÓSIO BRASILEIRO DE REDES NEURAI, 2, 1995, São Carlos. **Tutoriais,2**, São Carlos: SBC, 1995.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO
E METEOROLOGIA - CEPSRM
CURSO DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

**AVALIAÇÃO DO DESEMPENHO DE
CLASSIFICADORES NEURAIIS
PARA APLICAÇÕES EM SENSORIAMENTO REMOTO**

- ANEXOS -

por

VIVIANE TODT

Porto Alegre, RS
Junho de 1998

ANEXO 01. Lista de Figuras e Tabelas dos Anexos

Figura A1	Interação entre a Radiação Eletromagnética e Alvos da Superfície Terrestre	142
Figura A2	Nativa. Banda 1. (Histograma)	154
Figura A3	Nativa. Banda 2. (Histograma)	154
Figura A4	Nativa. Banda 3. (Histograma)	154
Figura A5	Nativa. Banda 4. (Histograma)	155
Figura A6	Nativa. Banda 5. (Histograma)	155
Figura A7	Nativa. Banda 7. (Histograma)	155
Figura A8	<i>Eucalyptus</i> . Banda 1. (Histograma)	156
Figura A9	<i>Eucalyptus</i> . Banda 2. (Histograma)	156
Figura A10	<i>Eucalyptus</i> . Banda 3. (Histograma)	156
Figura A11	<i>Eucalyptus</i> . Banda 4. (Histograma)	157
Figura A12	<i>Eucalyptus</i> . Banda 5. (Histograma)	157
Figura A13	<i>Eucalyptus</i> . Banda 7. (Histograma)	157
Figura A14	<i>Acácia</i> . Banda 1. (Histograma)	158
Figura A15	<i>Acácia</i> . Banda 2. (Histograma)	158
Figura A16	<i>Acácia</i> . Banda 3. (Histograma)	158
Figura A17	<i>Acácia</i> . Banda 4. (Histograma)	159
Figura A18	<i>Acácia</i> . Banda 5. (Histograma)	159
Figura A19	<i>Acácia</i> . Banda 7. (Histograma)	159
Figura A20	Pastagem. Banda 1. (Histograma)	160
Figura A21	Pastagem. Banda 2. (Histograma)	160
Figura A22	Pastagem. Banda 3. (Histograma)	160
Figura A23	Pastagem. Banda 4. (Histograma)	161
Figura A24	Pastagem. Banda 5. (Histograma)	161
Figura A25	Pastagem. Banda 7. (Histograma)	161
Figura A26	Solo Exposto. Banda 1. (Histograma)	162

Figura A27 Solo Exposto. Banda 2. (Histograma)	162
Figura A28 Solo Exposto. Banda 3. (Histograma)	162
Figura A29 Solo Exposto. Banda 4. (Histograma)	163
Figura A30 Solo Exposto. Banda 5. (Histograma)	163
Figura A31 Solo Exposto. Banda 7. (Histograma)	163
Figura A32 Água. Banda 1. (Histograma)	164
Figura A33 Água. Banda 2. (Histograma)	164
Figura A34 Água. Banda 3. (Histograma)	164
Figura A35 Água. Banda 4. (Histograma)	165
Figura A36 Água. Banda 5. (Histograma)	165
Figura A37 Água. Banda 7. (Histograma)	165
Figura A38 Amostra 01. (<i>Imagette</i>).....	168
Figura A39 Amostra 02. (<i>Imagette</i>).....	170
Figura A40 Amostra 03. (<i>Imagette</i>).....	172
Figura A41 Amostra 04. (<i>Imagette</i>).....	174
Figura A42 Amostra 05. (<i>Imagette</i>).....	177
Figura A43 Amostra 06. (<i>Imagette</i>).....	179
Figura A44 Amostra 07. (<i>Imagette</i>).....	181
Figura A45 Amostra 08. (<i>Imagette</i>).....	183
Figura A46 Amostra 09. (<i>Imagette</i>).....	186
Figura A47 Amostra 10. (<i>Imagette</i>).....	189
Figura A48 Amostra 11. (<i>Imagette</i>).....	191
Figura A49 Amostra 12. (<i>Imagette</i>).....	193
Figura A50 Reflorestamento de <i>Eucalyptus</i> (fundo) e Pastagem com capim alto (frente) (Foto Amostra 03).....	194
Figura A51 Faixa de Nativas (fundo), Pastagem (frente) e <i>Eucalyptus</i> (direita, frente) (Foto Amostra 03).....	194
Figura A52 Povoamento de <i>Acácia Negra</i> (vista da estrada) (Foto Amostra 03).....	195

Figura A53	Pastagem (frente) e Nativas (fundo) (Foto Amostra 05).....	195
Figura A54	<i>Acácia</i> (interior da área amostral) (Foto Amostra 06).....	196
Figura A55	Gomose em <i>Acácia</i> (Foto Amostra 06).....	196
Figura A56	Reflorestamento de <i>Eucalyptus Urophylla</i> da Riocell (vista da estrada em direção às Amostras 07 e 09)	197
Figura A57	Povoamento de <i>Acácia</i> (fundo), algumas poucas árvores Nativas (frente) e Pastagem entre Nativas e <i>Acácia</i> (vista da estrada) (Foto Amostra 10).....	197
Figura A58	Árvores Nativas (vista da estrada) (Foto Amostra 10).....	198
Figura A59	Nativas (em toda a margem do Rio Jacuí), Pastagem, Áreas Alagadas (mais ao fundo), Rio Jacuí (canto inferior direito) (Foto Amostra 11)	198
Figura A60	Árvores Nativas (Foto Amostra 12).....	199
Figura A61	Árvores Nativas (em toda a margem do Rio Jacuí) e Reflorestamento de <i>Eucalyptus</i> novo (< 3 anos, ao fundo).....	199
Figura A62	Exemplar de Nativas (centro) e Reflorestamento de <i>Eucalyptus</i> (atrás)	200
Figura A63	Exemplar de <i>Eucalyptus</i> (centro).....	200

Tabela AI	Satélites da Série <i>Landsat</i> . Fonte: Novo (1989)	146
Tabela AII	Características dos Satélites da Série <i>Landsat</i> . Fonte: Novo (1989)	148
Tabela AIII	Acertos obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de treinamento (em <i>pixels</i>)	224
Tabela AIV	Distribuição de erros obtidos pelo Método de Máxima Verossimilhança Gaussiana para o conjunto de treinamento (em <i>pixels</i>).....	224
Tabela AV	Acertos obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de reconhecimento (em <i>pixels</i>).....	225
Tabela AVI	Distribuição de erros obtidos pelo Método de Máxima Verossimilhança Gaussiana para o conjunto de reconhecimento (em <i>pixels</i>)	225
Tabela AVII	Acertos obtidos pela Rede Neural Multinível com <i>BackPropagation</i> para o conjunto de treinamento (em <i>pixels</i>)	226
Tabela AVIII	Distribuição de erros obtidos pela Rede Neural Multinível com <i>Backpropagation</i> para o conjunto de treinamento (em <i>pixels</i>)	226
Tabela AIX	Acertos obtidos pela Rede Neural Multinível com <i>BackPropagation</i> para o conjunto de reconhecimento (em <i>pixels</i>).....	227
Tabela AX	Distribuição de erros obtidos pela Rede Neural Multinível com <i>BackPropagation</i> para o conjunto de reconhecimento (em <i>pixels</i>).....	227

ANEXO 02. Princípios Básicos de Sensoriamento Remoto

Absortância, Reflectância e Transmitância

Conforme Novo (1989), Sensoriamento Remoto é a utilização de sensores para a aquisição de informações sobre objetos ou fenômenos sem que haja contato direto entre eles. E, sensores são equipamentos capazes de coletar energia proveniente do objeto, convertê-la em sinal passível de ser registrado e apresentá-lo em forma adequada à extração de informações.

Os sensores a bordo de um satélite (*Landsat*, *SPOT*) captam as interações entre a radiação eletromagnética e os alvos da superfície terrestre (Figura A1).

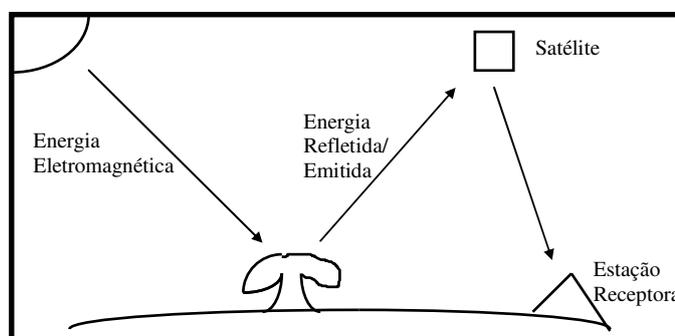


FIGURA A1 - Interação entre a Radiação Eletromagnética e Alvos da Superfície Terrestre

Quando a energia incidente, proveniente dos raios solares, interage com os alvos terrestres, parte desta energia é absorvida, parte é refletida e outra parte é transmitida pelo próprio alvo. Ou, de outra maneira pode-se dizer:

$$E_i(\lambda) = E_r(\lambda) + E_a(\lambda) + E_t(\lambda),$$

onde E_i é a energia incidente, E_r é a energia refletida, E_a é a energia absorvida e E_t é a energia transmitida pelo alvo para um dado comprimento de onda.

O quanto de energia será refletida, absorvida ou transmitida depende do tipo e da condição do alvo e do comprimento de onda da radiação incidente. Por exemplo: a vegetação reflete bastante no IV próximo se comparada com o solo argiloso; conseqüentemente, o solo argiloso possui uma absorção muito maior, nesta faixa espectral, do que a vegetação (Figura 2.26).

Ao se dividir cada um dos termos da equação anterior por $E_i(\lambda)$, se obtém a seguinte equação:

$$1 = \rho(\lambda) + \alpha(\lambda) + \tau(\lambda),$$

onde $\rho(\lambda)$ é a reflectância, $\alpha(\lambda)$ é a absorptância e $\tau(\lambda)$ é a transmitância. Ou seja, estes três valores passam a representar porcentagens da energia incidente que é refletida, absorvida e transmitida pelo alvo, em um determinado intervalo de comprimento de onda. A energia absorvida por um corpo ou é consumida por ele, para uso em processos físicos/biológicos (como a fotossíntese e a evapotranspiração), ou é liberada na forma de calor. Essa energia liberada é denominada energia emitida.

Assim, para um alvo em estado de equilíbrio, é possível estabelecer a seguinte relação:

$$\varepsilon(\lambda) \cong \alpha(\lambda)$$

Logo:

$$1 = \rho(\lambda) + \varepsilon(\lambda) + \tau(\lambda)$$

Desta forma, na região do termal (ou emissiva) do espectro-eletromagnético, alvos com baixa reflectância possuem alta emitância, que é consequência de uma alta absorptância¹. E, em termos de níveis de cinza, os alvos mais escuros são os que liberam uma maior quantidade de calor.

Conforme Fontana (1995), quando o objetivo é monitorar a superfície da Terra, utilizando sensores a bordo de satélites, assume-se que os alvos são opacos à radiação, ou seja, a transmissividade é igual a zero, com exceção da água. Desta forma, vale a seguinte equação:

$$1 = \rho(\lambda) + \varepsilon(\lambda)$$

Outro detalhe importante é o fato de que, em Sensoriamento Remoto, somente algumas partes do espectro-eletromagnético são utilizados: visível, IV próximo, IV médio e IV termal. Isto ocorre pois de toda a radiação que atinge o topo da atmosfera, menos de 100% a atravessa atingindo os alvos. Os comprimentos de onda

¹ Válido para alvos que não possuem processos físicos/biológicos.

curtos são absorvidos por gases como: CO₂, O₃ e vapor d'água que os reemitem em comprimentos de onda mais longos, sob a forma de calor.

Imagens Digitais

Conforme citado anteriormente, os sensores a bordo de um satélite registram a interação entre a radiação eletromagnética, proveniente do sol, e os alvos da superfície terrestre. A energia refletida e emitida pelos alvos são coletadas como sinais elétricos. Esses, por sua vez, são transmitidos como sinais analógicos para uma estação receptora que os converte em sinais digitais (níveis de cinza).

Portanto, as imagens de satélite são arranjos de sinais digitais dispostos em linhas e colunas. Ou, de outra forma, cada ponto (ou *pixel*) de uma imagem representa a resposta de alvos à interação eletromagnética, em um determinado intervalo de comprimento de onda.

O satélite *LANDSAT 5-TM*, por possuir sete sensores, produz sete imagens digitais, cada qual denominada banda. Cada banda registra a energia refletida ou emitida, pelos alvos da superfície terrestre, em uma determinada faixa do espectro-eletromagnético. Para esse satélite, as bandas 1, 2, 3, 4 5 e 7 coletam a energia refletida, enquanto que a banda 6 coleta a energia emitida pelos alvos.

Resolução Espacial, Espectral e Radiométrica

É impossível falar em sensor sem fazer referência a sua resolução espacial, espectral e radiométrica.

Resolução é uma medida da habilidade que um sistema sensor possui de distinguir entre respostas que são semelhantes espectralmente ou próximas espacialmente (NOVO, 1989).

A resolução espacial refere-se à distância mínima que deve existir entre dois alvos para que esses possam ser discriminados entre si. Diz respeito, também, ao tamanho de uma área do terreno cuja resposta espectral está contida em um *pixel*. Assim, uma resolução espacial de 30 metros significa que cada *pixel* cobre 30 m x 30 m da área *imageada*. Desta forma, um alvo para ser identificado precisa ter 900 m² a fim

de ocupar, pelo menos, um *pixel* na imagem. Caso contrário, o valor do *pixel* equivale à energia que chega ao sensor em função de um conjunto de alvos menores².

A resolução espectral refere-se à quantidade e à largura das faixas espectrais do sensor. Quanto maior o número de regiões do espectro-eletromagnético abrangidas pelo sensor, em geral, maior é a sua resolução. Entretanto, a largura das faixas é importante, pois quanto menor é a faixa, maior é a capacidade do sensor em registrar pequenas variações no comportamento espectral. Para a obtenção de uma resolução espectral ótima, a quantidade de bandas deveria aumentar infinitamente, enquanto que a largura das faixas deveria diminuir. Porém, isto está limitado às condições tecnológicas possíveis até o momento.

Já a resolução radiométrica refere-se ao intervalo de valores de níveis de cinza ao qual o intervalo de comprimento de onda, detectado pelo sensor, será discretizado. Quanto maior o intervalo de níveis de cinza, maior é a resolução radiométrica, pois maior distinção na resposta espectral dos alvos pode ser obtida.

O satélite *LANDSAT 5-TM* possui uma resolução espacial de 30 metros (com exceção do canal 6 que é de 120 m), uma resolução radiométrica de 8 bits (256 níveis de cinza – do zero ao 255) e sua resolução espectral é função de sete bandas que cobrem partes do espectro-eletromagnético entre 0.45 μm e 2.35 μm ³.

Maiores informações sobre os princípios básicos de Sensoriamento Remoto podem ser encontradas em NOVO (1989) e RICHARDS (1986).

² Diz-se *pixel* mistura aquele *pixel* cujo valor é o conjunto de respostas espectrais de diversos alvos menores. A ocorrência de *pixels* mistura é muito comum, pois seguidamente em uma área de 900 m² encontra-se vegetação, água, asfalto, entre outros.

³ O Anexo 03 mostra as regiões espectrais cobertas por cada banda.

ANEXO 03. Características dos Sistemas *Landsat*⁴

O Sistema *LANDSAT*, desenvolvido pela *National Aeronautics and Space Administration (NASA)*, é uma plataforma espacial para a coleta de dados sobre os recursos da superfície terrestre. O primeiro satélite da série, denominado *Earth Resources Technology Satellite -1 (ERTS-1)*, foi lançado em 1972. Porém, seus dados só começaram a ser recebidos no Brasil em 1973, através de estações receptoras do Instituto Nacional de Pesquisas Espaciais (INPE). A partir desta data, mais quatro satélites foram lançados, porém, passaram a ser chamados de *LANDSAT*. A Tabela AI, apresenta o tempo de vida útil e os sensores (RBV, MSS e TM) carregados a bordo de cada um dos satélites desta série.

TABELA AI - Satélites da Série *LANDSAT*. Fonte: NOVO (1989)

SATÉLITE	DATA DE LANÇAMENTO	TÉRMINO DA OPERAÇÃO	SENSORES A BORDO
<i>ERTS 1</i>	jul/72	jan/78	<ul style="list-style-type: none">• MSS 4 canais - resolução espacial de 80 m;• 3 câmeras RBV - 3 canais - resolução espacial de 80 m.
<i>LANDSAT 2</i>	jan/75	jul/83	<ul style="list-style-type: none">• MSS 4 canais - resolução espacial de 80 m;• 3 câmeras RBV - 3 canais - resolução espacial de 80 m.
<i>LANDSAT 3</i>	mar/78	set/83	<ul style="list-style-type: none">• MSS 5 canais, sendo que um deles operou na região do Infravermelho Termal – resolução espacial de 80 m e 240 m;• 2 câmeras RBV - 1 canal - resolução espacial de 30 m.
<i>LANDSAT 4</i>	jul/82	----	<ul style="list-style-type: none">• MSS 4 canais - resolução espacial de 80 m;• TM 7 canais - resolução espacial de 30 m e 120 m.
<i>LANDSAT 5</i>	mar/84	----	<ul style="list-style-type: none">• MSS 4 canais - resolução espacial de 80 m;• TM 7 canais - resolução espacial de 30 m e 120 m.

O sistema RBV (*Return Beam Vidicom*) é um sistema semelhante a uma câmera fotográfica que permite o registro instantâneo de uma certa área do terreno (cena). A energia proveniente de toda a cena impressiona a superfície fotossensível do tubo da câmera e durante certo tempo a entrada de energia é interrompida por um obturador para que a imagem do terreno seja varrida por um feixe de elétrons. O sinal

⁴ Informações obtidas de NOVO (1989) e JENSEN (1986)

produzido pode, então, ser transmitido telemetricamente. Nota-se que este sinal é proporcional à intensidade de energia emitida ou refletida pela superfície terrestre.

Para os dois primeiros satélites da série, o sistema RBV consistia de três câmeras independentes que operavam simultaneamente sensoriando a mesma superfície, em 3 faixas do espectro-eletromagnético determinadas através de filtros especiais. Já para o *LANDSAT 3*, o sistema RBV foi revisto de maneira que as duas câmeras RBV operaram em uma única faixa espectral, o que permitiu uma melhor resolução espacial do que o sensor MSS (*Multispectral Scanner Subsystem*).

O sensor MSS é um sistema de varredura multi-espectral que permite o *imageamento* de linhas do terreno em faixas de 185 Km e largura. A varredura do sistema é realizada com o auxílio de um espelho que oscila perpendicularmente ao deslocamento do satélite. Foi utilizado como um sensor alternativo ao RBV.

Por sua vez, o sensor TM (*Thematic Mapper*) é semelhante ao MSS, pois também é um sistema de varredura de linhas. Porém, ele contém uma série de aperfeiçoamentos tanto em seus componentes óticos quanto eletrônicos, além de operar em 7 faixas espectrais. Esse sensor foi concebido para proporcionar uma resolução espacial mais fina, melhor discriminação espectral entre objetos da superfície terrestre, maior fidelidade geométrica e melhor precisão radiométrica em relação ao sensor MSS.

Nota-se que do *LANDSAT 1* ao *LANDSAT 5* houve um aumento do número de canais (o que corresponde a um aumento da resolução espectral nas imagens obtidas) e um melhor desempenho em termos de resolução espacial. E, a tendência é o surgimento de sensores cada vez mais eficientes.

Por fim, a Tabela AII apresenta a altitude e as características da órbita de cada um dos satélites da série *LANDSAT* lançados até o momento.

TABELA AII – Características dos satélites da série *LANDSAT*. Fonte: NOVO (1989)

SATÉLITE	ALTITUDE (Km)	ÓRBITA
<i>LANDSAT 1, 2 e 3</i>	920	<ul style="list-style-type: none"> • Circular⁵, quase polar, síncrona com o sol⁶, inclinação de 99°11' em relação ao Equador; • Cobertura de 14 faixas da superfície terrestre por dia, entre as latitudes de 81°N e 81°S; • Passagem a cada 18 dias sobre um mesmo ponto da superfície terrestre (resolução temporal); • Horário médio de passagem pelo Equador: 9h15min (manhã).
<i>LANDSAT 4 e 5</i>	705	<ul style="list-style-type: none"> • Circular, quase polar, síncrona com o sol, inclinação de 99°11' em relação ao Equador; • Cobertura de 14 faixas da superfície terrestre por dia, entre as latitudes de 81°N e 81°S; • Passagem a cada 16 dias sobre um mesmo ponto da superfície terrestre (resolução temporal); • Horário médio de passagem pelo Equador: 9h45min (manhã).

⁵ A órbita circular garante que as imagens obtidas em diferentes regiões da Terra possuam a mesma resolução e escala.

⁶ A órbita síncrona com o sol permite que os dados sejam coletados sob condições de iluminação local similares.

ANEXO 04. Regiões Fisiográficas do Rio Grande do Sul.
 Fonte: (IBDF, 1983)

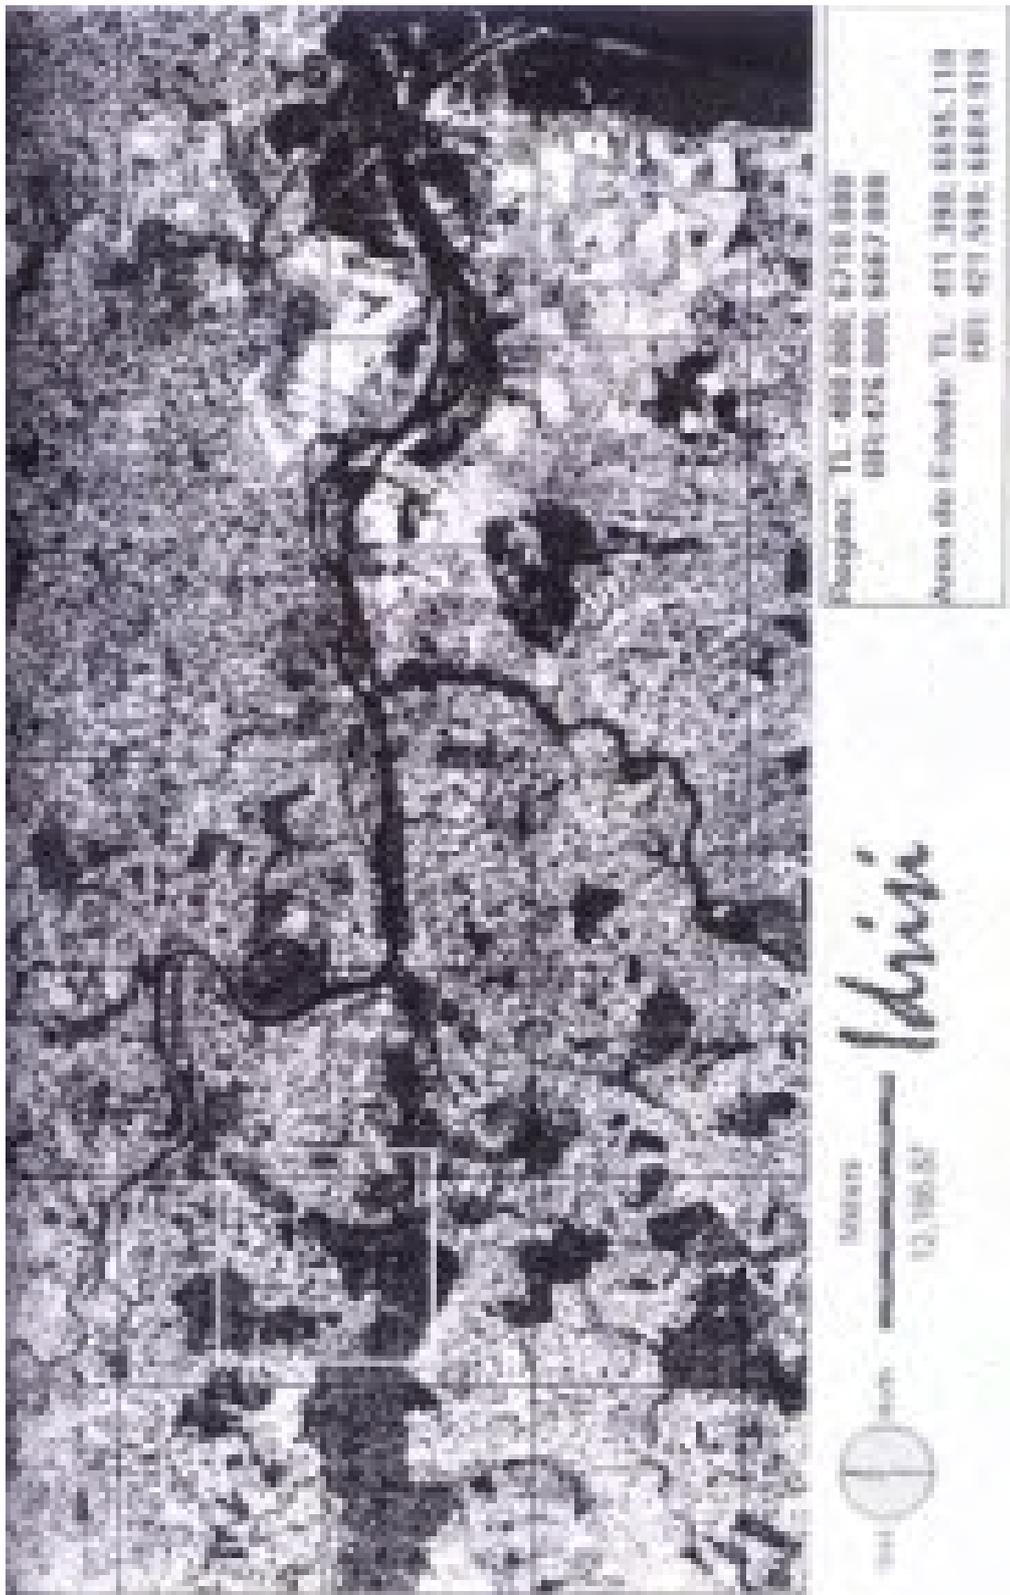


- 1 - Litoral
- 2 - Depressão Central
- 3 - Encosta do Sudeste
- 4 - Serra do Sudeste
- 5 - Campanha
- 6 - Missões
- 7 - Alto Uruguai
- 8 - Planalto Médio
- 9 - Encosta Inferior do NE
- 10 - Encosta Superior do NE
- 11 - Campos de Cima da Serra

ANEXO 05. Micro-Regiões do Rio Grande do Sul. Fonte: (IBDF,1983)

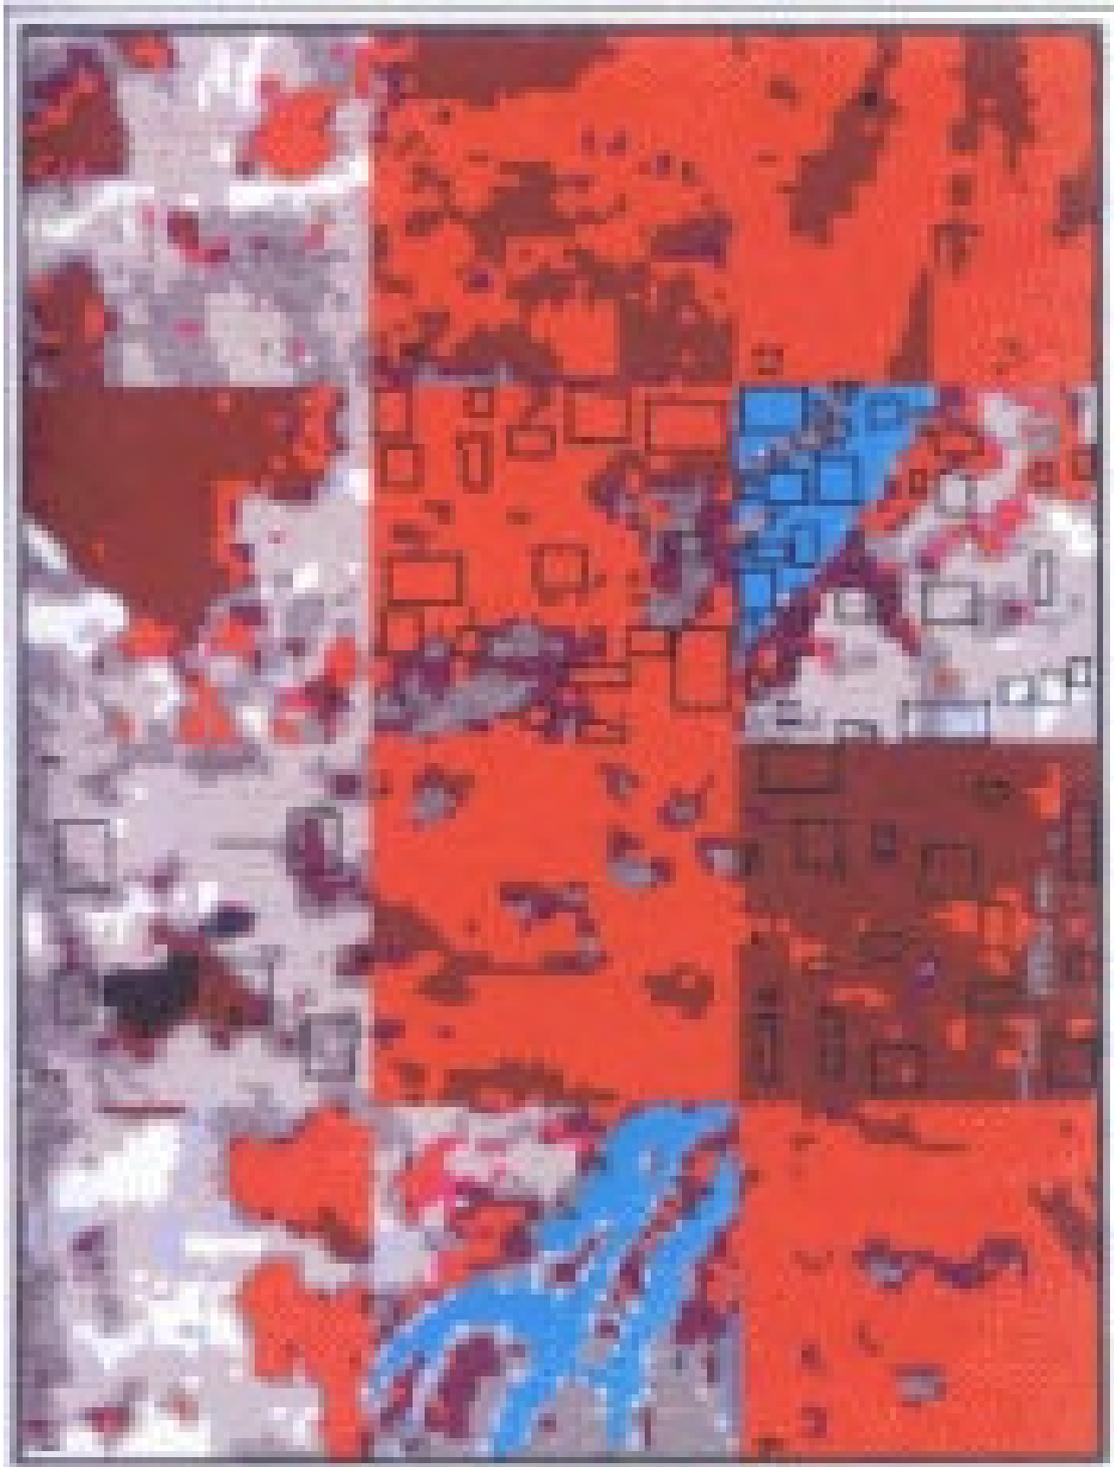


ANEXO 06. Área de Estudo em relação à Capital Metropolitana



LANDSAT TM, RGB 432, 25 METROS, 76 X 43 Km, GRADE 10 X 10 Km

ANEXO 07. Amostras para o treinamento dos classificadores supervisionados



ANEXO 08. Resultados obtidos com o Georeferenciamento⁷

Resample : Summary of Transformation

Computed polynomial surface : Quadratic (based on 11 control points)

Coefficient	X	Y
b0	-560770.9422607421880000	-6790095.9272460937500000
b1	1.0658666329454718	0.2411278167001001
b2	0.2107978952262783	1.0279161202051910
b3	-0.0000000066028167	-0.0000000173869829
b4	-0.0000000108383331	-0.0000000096919152
b5	-0.0000000273257263	-0.0000000026839399

Note : Figures are carried internally to 20 significant figures.
Formula shown is the back transformation (new to old).

Control points used in the transformation :

Old X	Old Y	New X	New Y	Residual
25040.000000	60530.000000	406425.000000	6715550.000000	34.325065
35895.000000	60600.000000	417150.000000	6713825.000000	10.050076
45165.000000	15900.000000	419200.000000	6668250.000000	18.135444
66000.000000	48360.000000	444900.000000	6696900.000000	17.994126
60585.000000	19305.000000	434925.000000	6669125.000000	5.840389
74475.000000	16485.000000	448175.000000	6664125.000000	20.658634
78810.000000	70320.000000	461050.000000	6716550.000000	24.107114
9270.000000	42990.000000	388075.000000	6700775.000000	11.825016
17600.000000	61350.000000	399250.000000	6717525.000000	18.624325
38140.000000	89770.000000	424075.000000	6742225.000000	12.433253
93670.000000	46870.000000	471975.000000	6691000.000000	17.711443

Overall RMS = 18.899054

Note : RMS Error is expressed in input image units. With low RMS errors, be careful that an adequate sample exists (eg. 2-3 times the mathematical min).

⁷Resultados fornecidos pelo *software* Idrisi.

ANEXO 09. Histograma das classes/banda

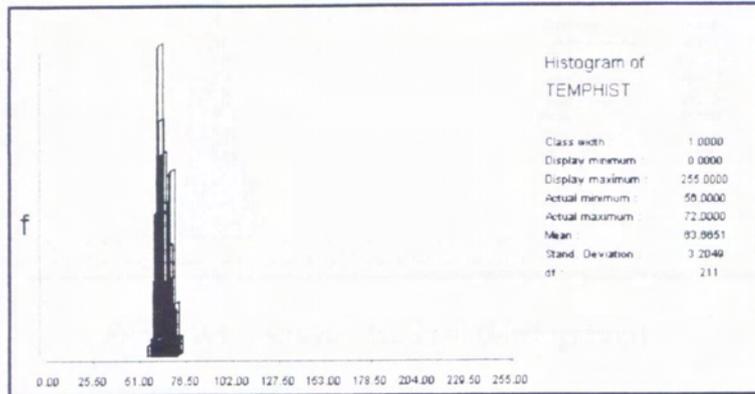


Figura A2 - Nativa. Banda 1. (Histograma)

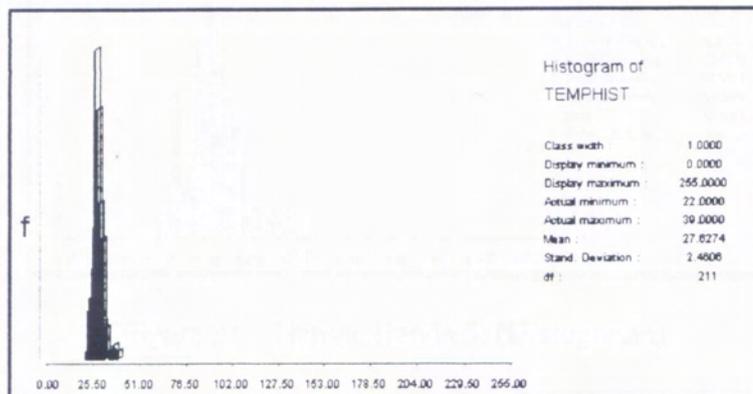


Figura A3 - Nativa. Banda 2. (Histograma)

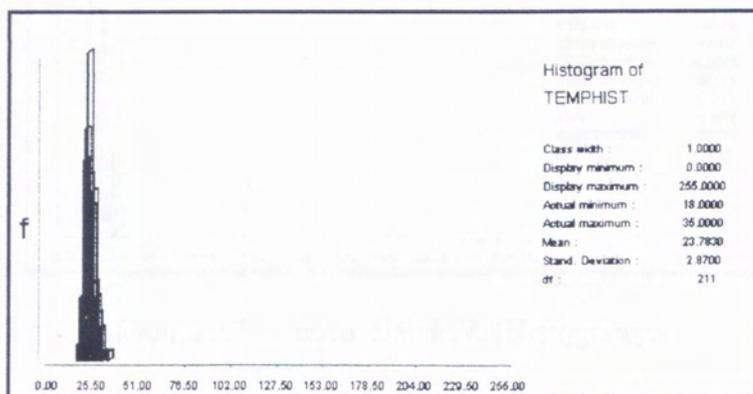


Figura A4 - Nativa. Banda 3. (Histograma)

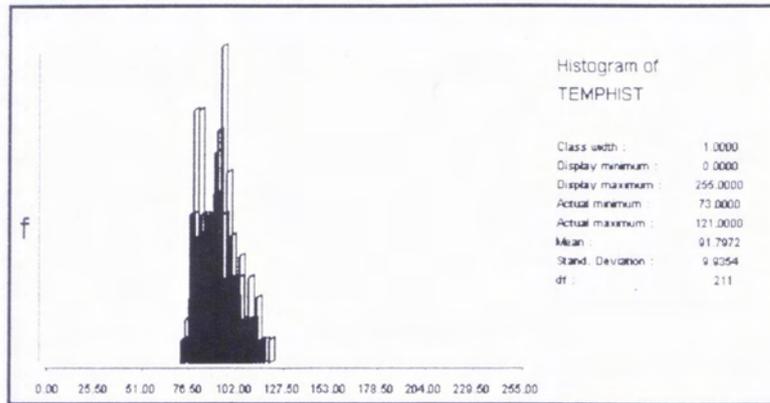


Figura A5 - Nativa. Banda 4. (Histograma)

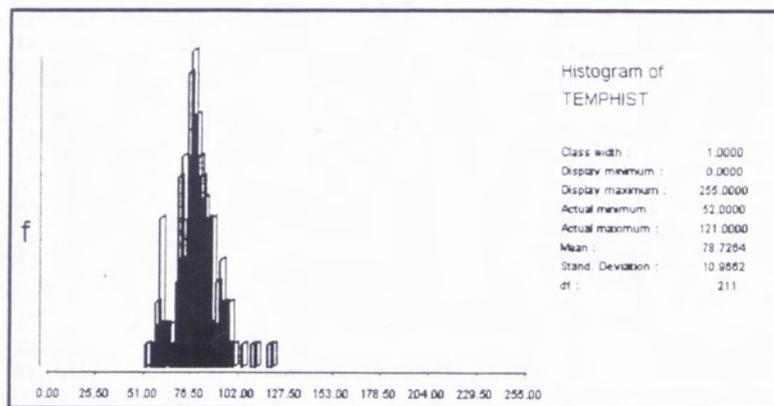


Figura A6 - Nativa. Banda 5. (Histograma)

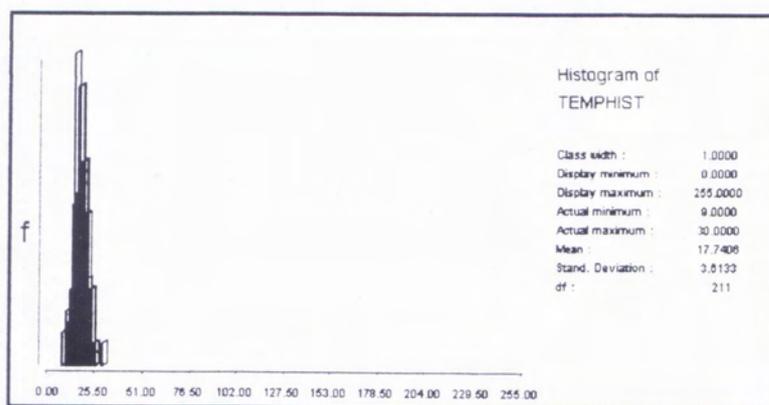


Figura A7 - Nativa. Banda 7. (Histograma)

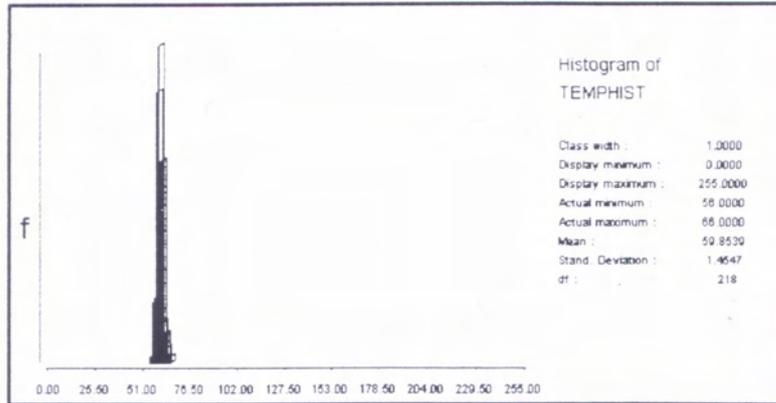


Figura A8 - *Eucalyptus*. Banda 1. (Histograma)

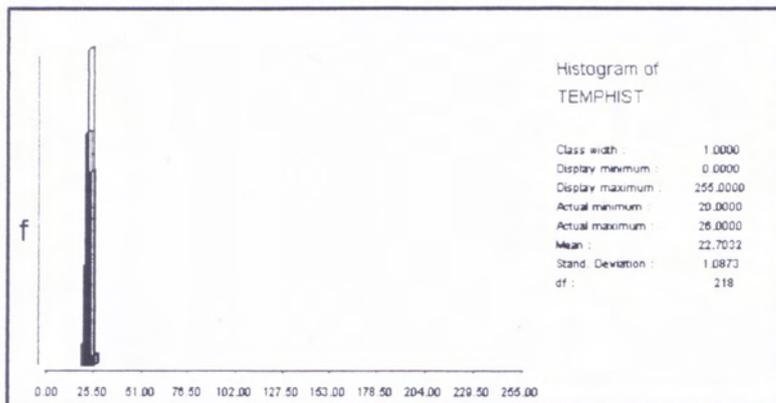


Figura A9 - *Eucalyptus*. Banda 2. (Histograma)

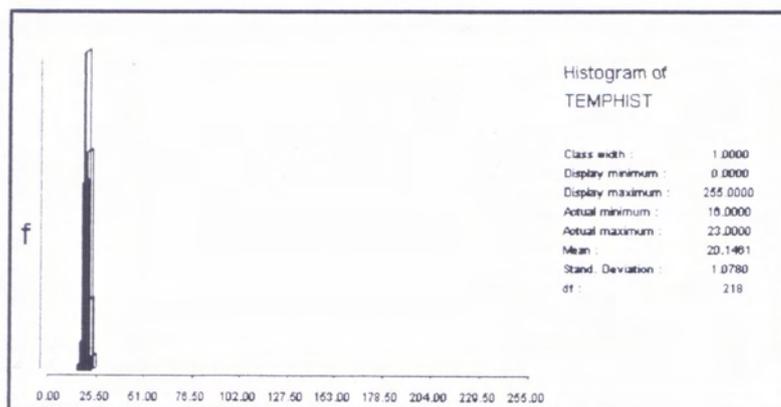


Figura A10 - *Eucalyptus*. Banda 3. (Histograma)

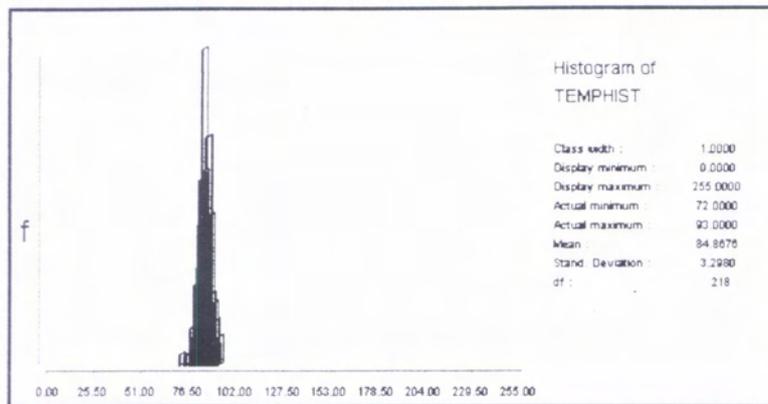


Figura A11 - *Eucalyptus*. Banda 4. (Histograma)

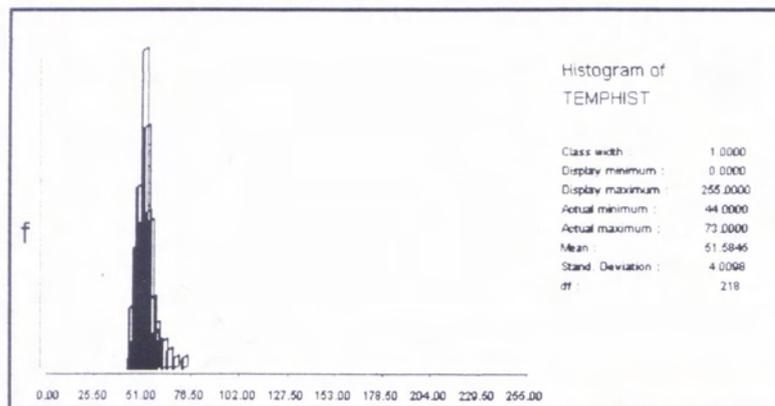


Figura A12 - *Eucalyptus*. Banda 5. (Histograma)

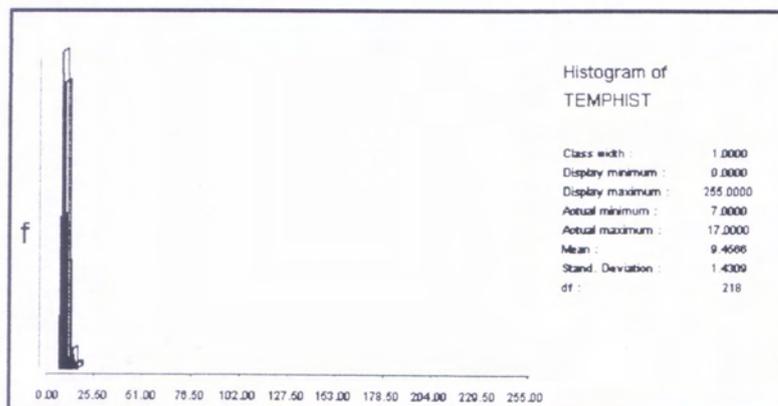


Figura A13 - *Eucalyptus*. Banda 7. (Histograma)

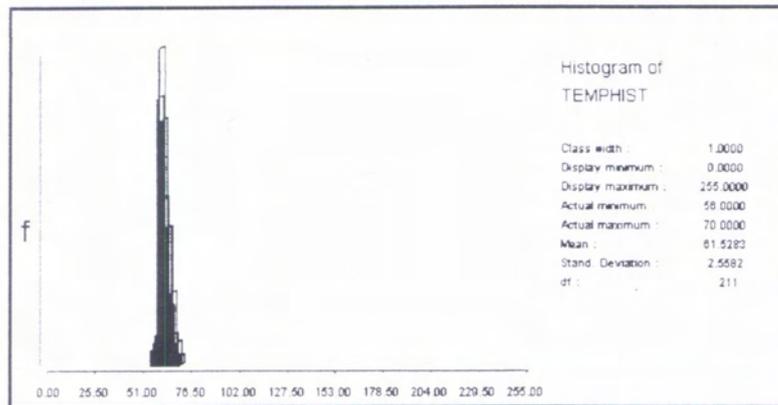


Figura A14 - *Acácia*. Banda 1. (Histograma)

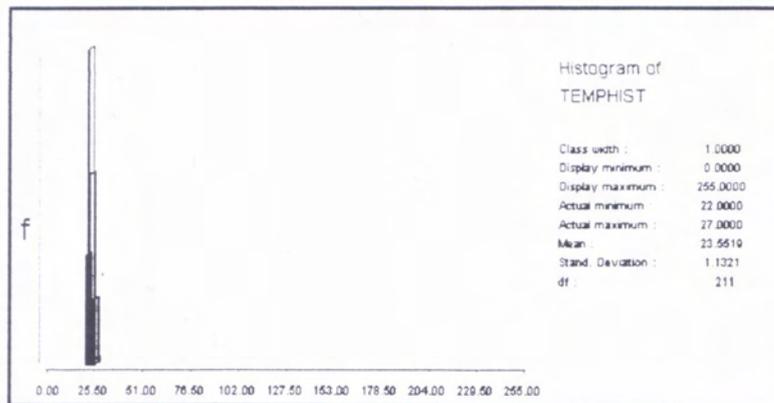


Figura A15 - *Acácia*. Banda 2. (Histograma)

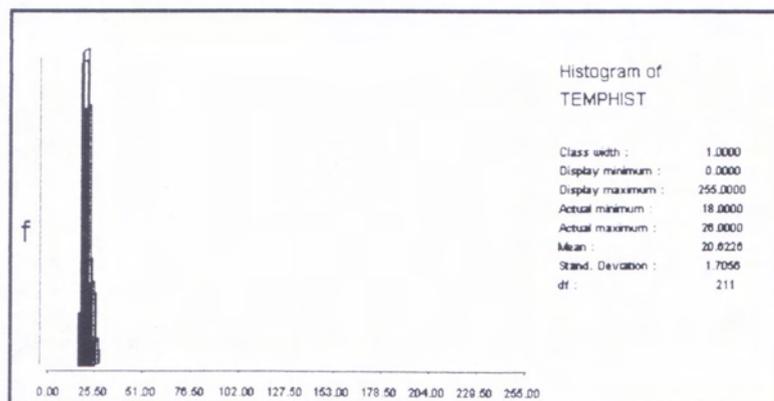


Figura A16 - *Acácia*. Banda 3. (Histograma)

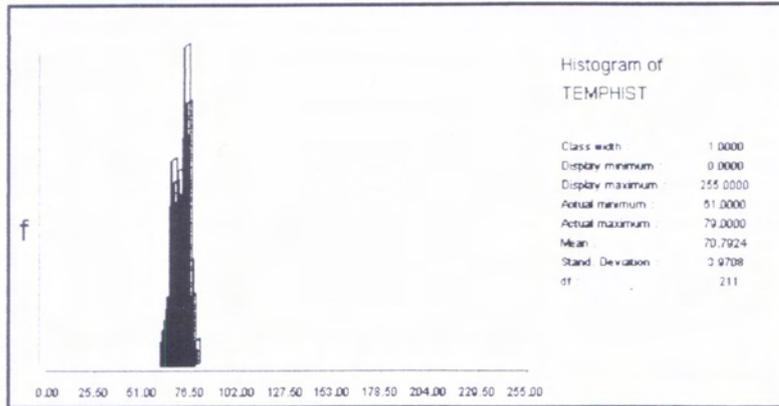


Figura A17 - *Acácia*. Banda 4. (Histograma)

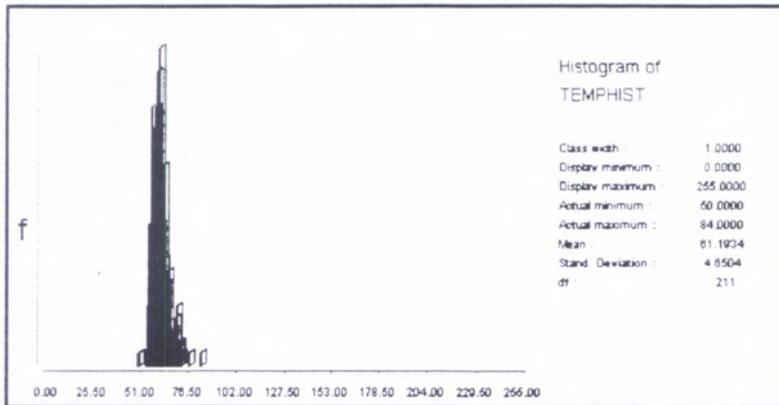


Figura A18 - *Acácia*. Banda 5. (Histograma)

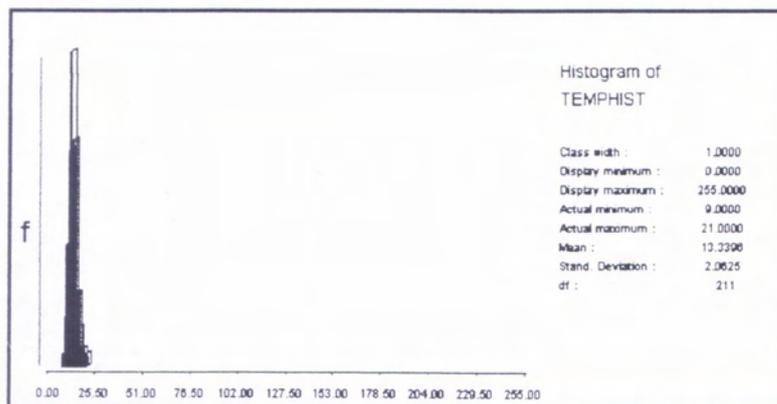


Figura A19 - *Acácia*. Banda 7. (Histograma)

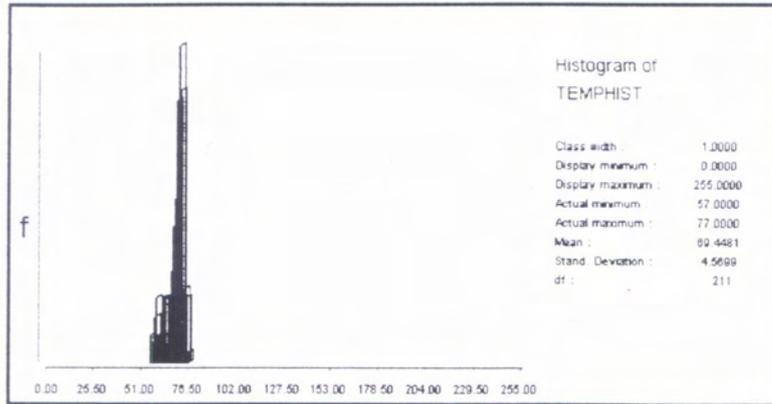


Figura A20 - Pastagem. Banda 1. (Histograma)

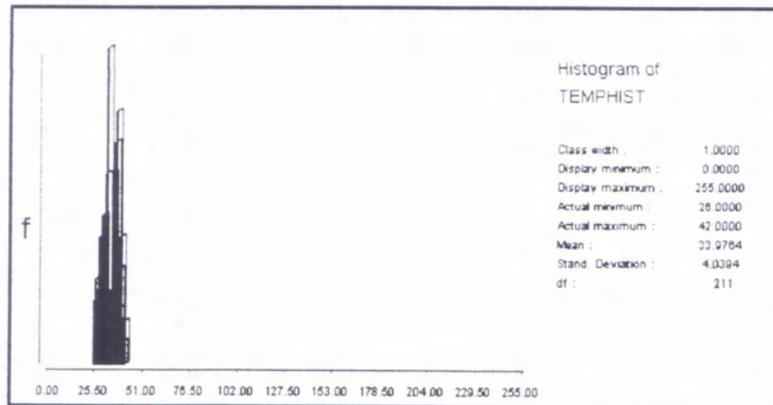


Figura A21 - Pastagem. Banda 2. (Histograma)

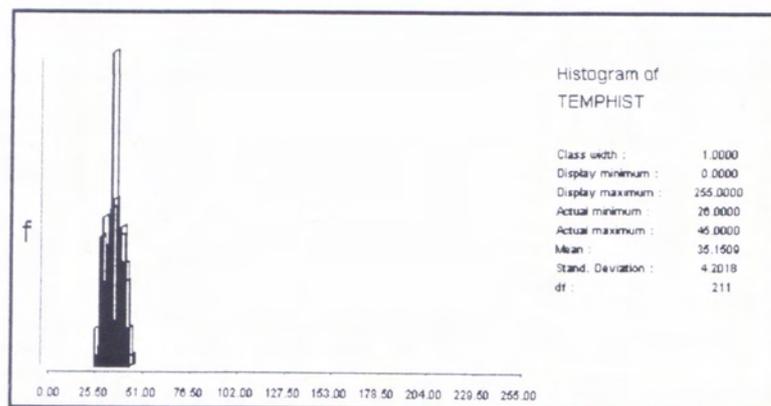


Figura A22 - Pastagem. Banda 3. (Histograma)

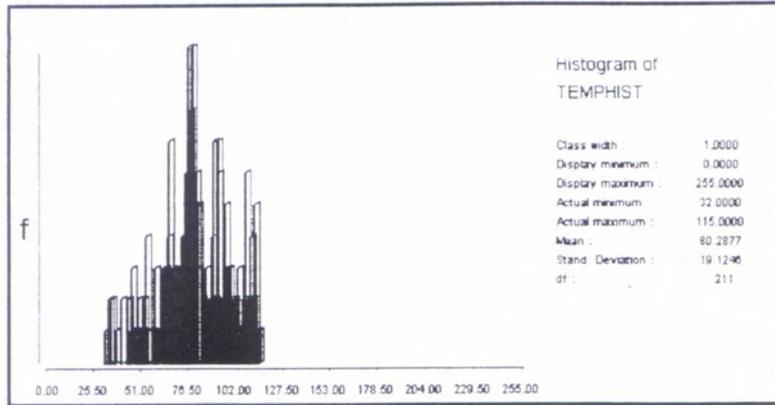


Figura A23 - Pastagem. Banda 4.(Histograma)

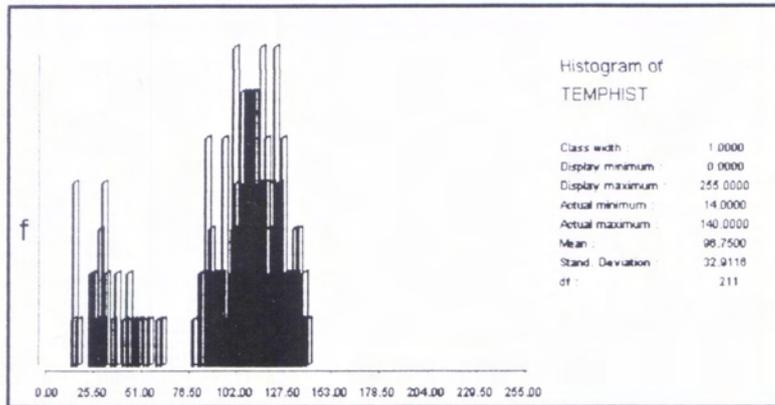


Figura A24 - Pastagem. Banda 5. (Histograma)

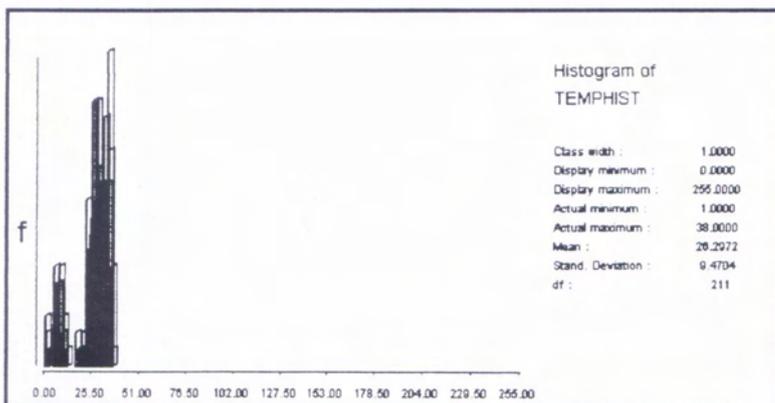


Figura A25 - Pastagem. Banda 7. (Histograma)

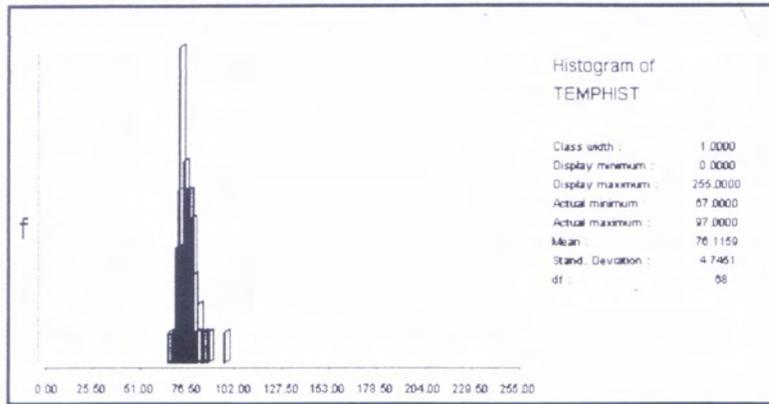


Figura A26 - Solo Exposto. Banda 1. (Histograma)

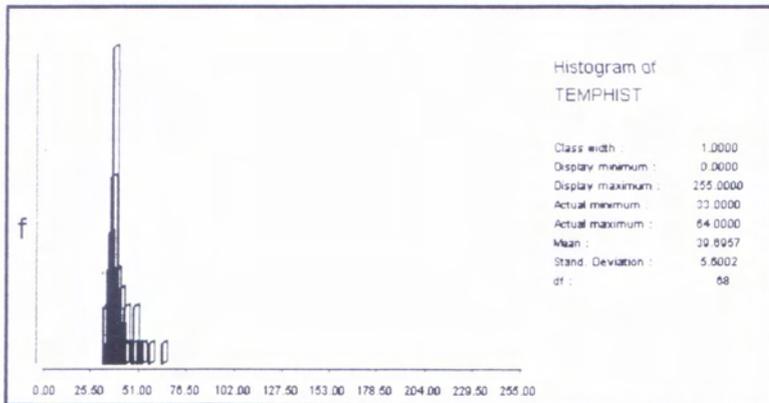


Figura A27 - Solo Exposto. Banda 2. (Histograma)

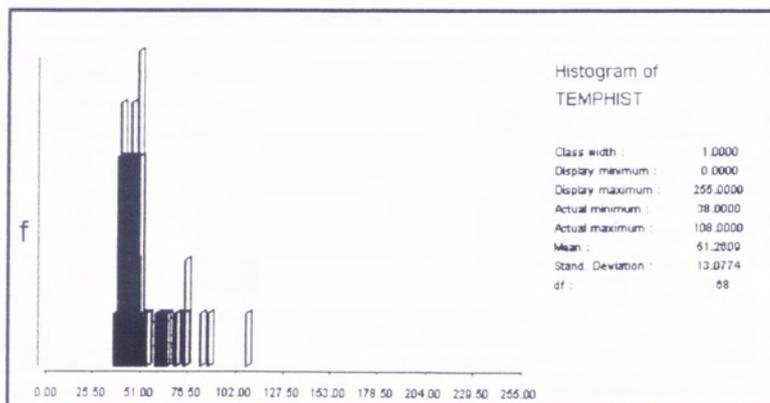


Figura A28 - Solo Exposto. Banda 3. (Histograma)

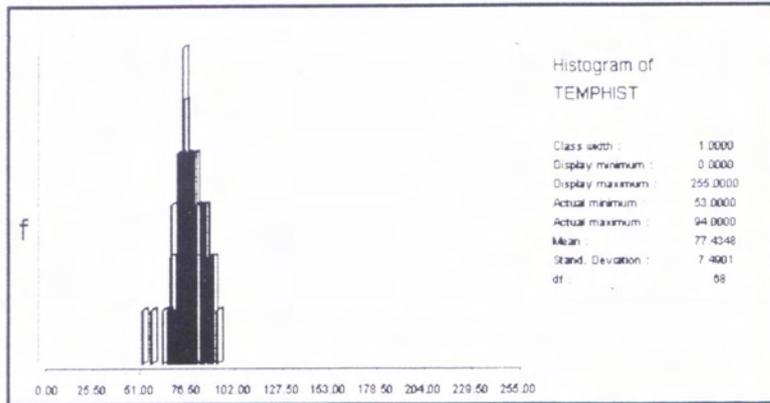


Figura A29 - Solo Exposto. Banda 4. (Histograma)

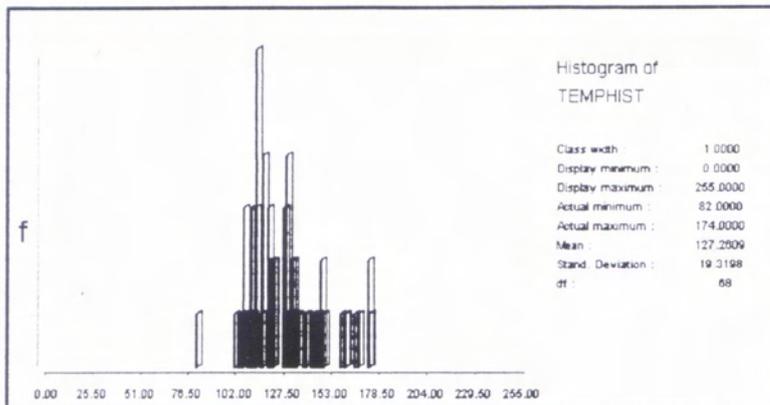


Figura A30 - Solo Exposto. Banda 5. (Histograma)

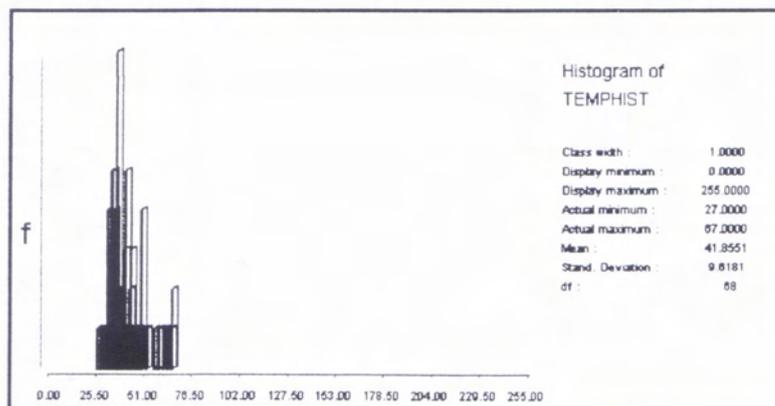


Figura A31 - Solo Exposto. Banda 7. (Histograma)

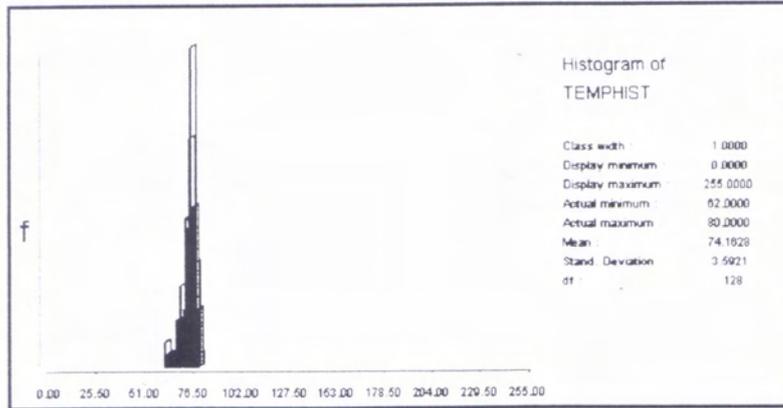


Figura A32 - Água. Banda 1. (Histograma)

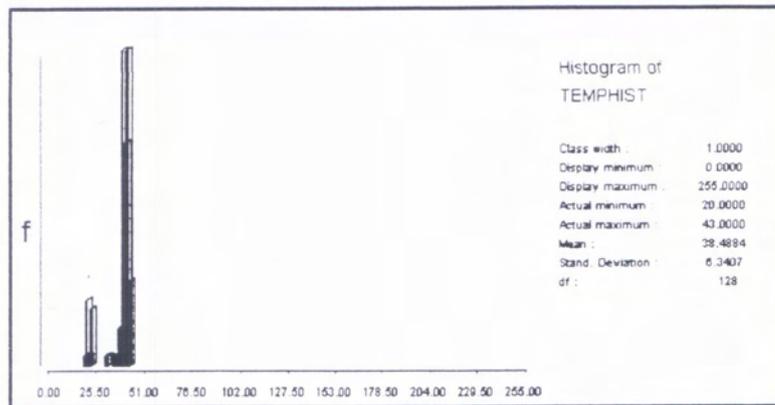


Figura A33 - Água. Banda 2. (Histograma)

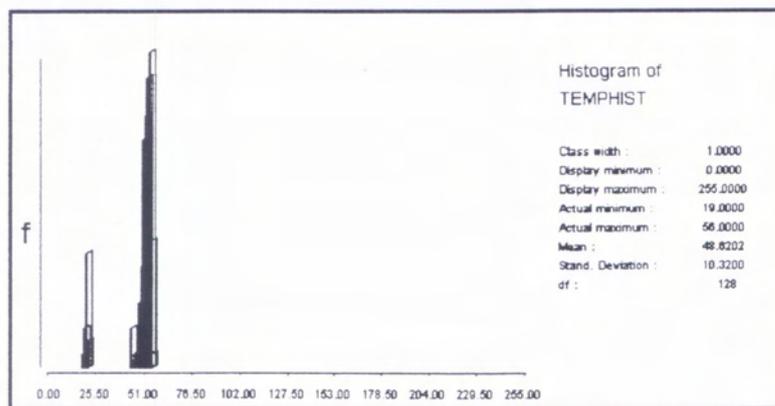


Figura A34 - Água. Banda 3. (Histograma)

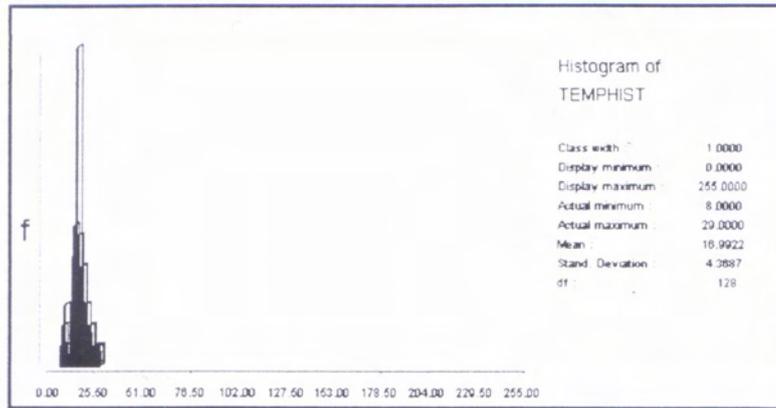


Figura A35 - Água. Banda 4. (Histograma)

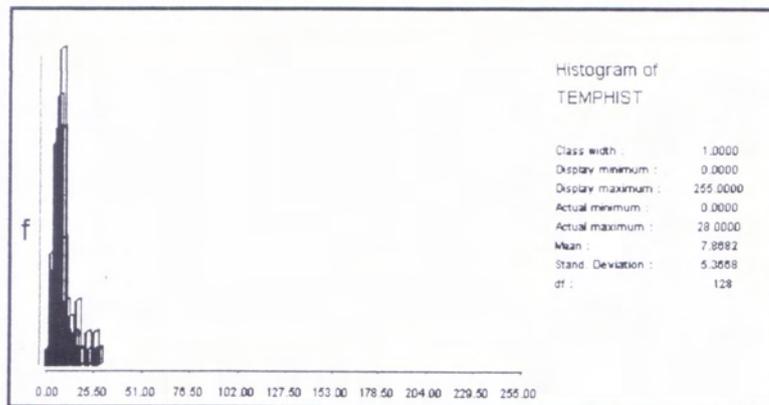


Figura A36 - Água. Banda 5. (Histograma)

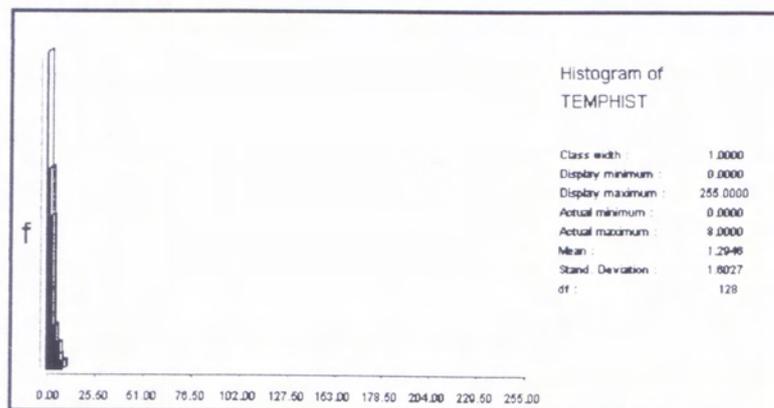


Figura A37 - Água. Banda 7. (Histograma)

ANEXO 10. Áreas Amostras (*imagettes*) e seus respectivos Formulários

As próximas páginas mostram cada uma das *imagettes* confeccionadas para a etapa de verificação de campo, os formulários utilizados e algumas fotos da região. As classes foram identificadas em cada *imagerie* e, devidamente, registradas nos formulários (com seu nome, código e data em que foram mapeadas). A coluna de hectares não foi preenchida, pois esta informação não se encontrava disponível.

FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)

BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

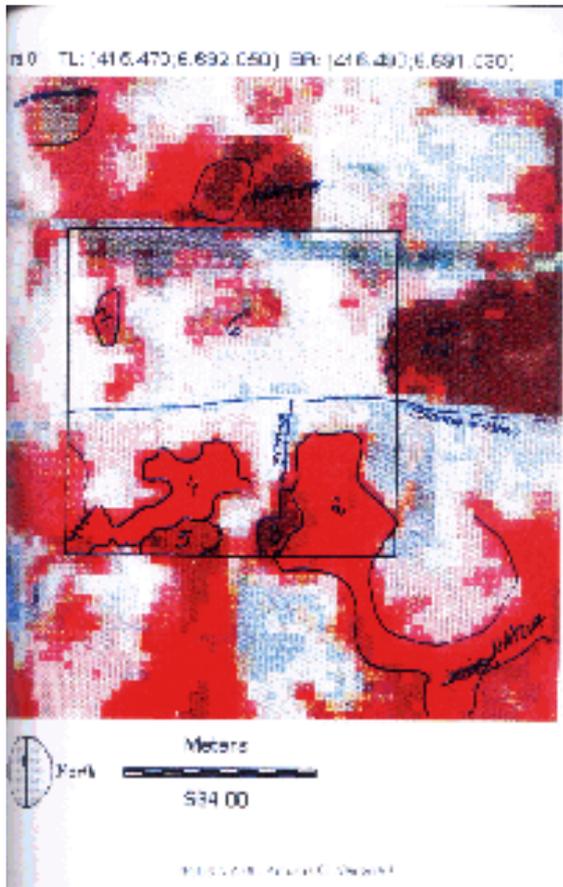
Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

AMOSTRA: 01

DATA: 19/12/96

NÚM.: 01/01

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
1	<i>Acácia (corte)</i>	3	
2	Nativa	1	
3	<i>Eucalyptus</i>	2	
4	Nativa	1	
5	<i>Eucalyptus</i>	2	
6	Pastagem	4	
7	Nativa	1	
8			
9			
10			



FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)
BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

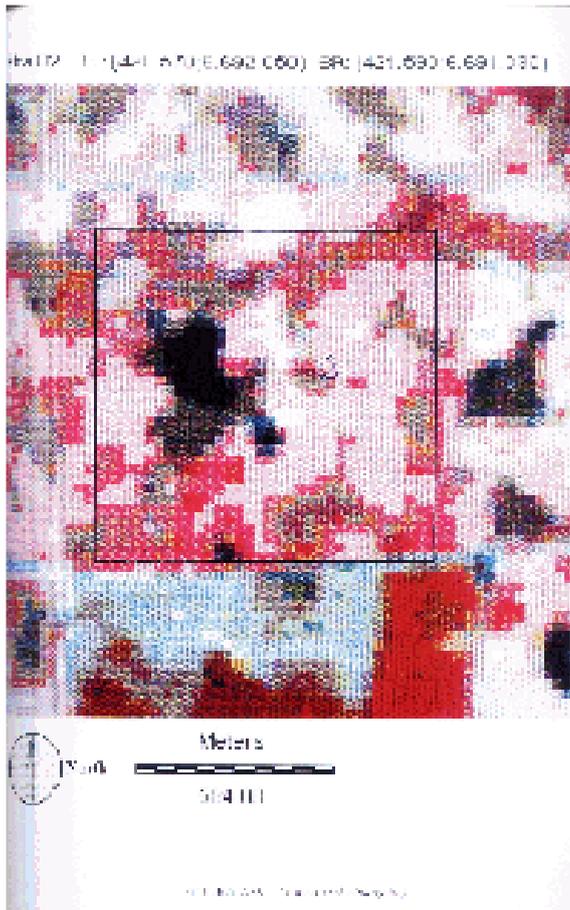
Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

AMOSTRA: 02

DATA: 19/12/96

NÚM.: 01/01

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
1	Água	6	
2	Pastagem (úmida/seca)	4	
3			
4			
5			
6			
7			
8			
9			
10			



FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)
BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

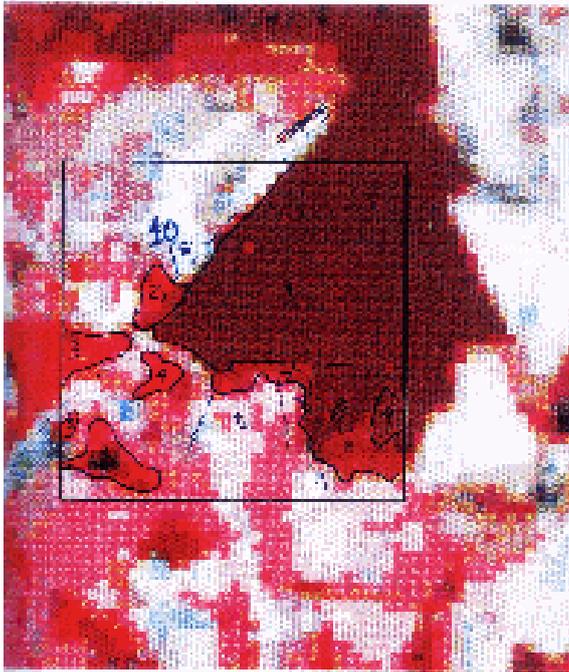
AMOSTRA: 03

DATA: 17/01/97

NÚM.: 01/01

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
1	<i>Acácia (corte)</i>	3	
2	Nativa	1	
3	Nativa	1	
4	Nativa	1	
5	Nativa	1	
6	Nativa	1	
7	Nativa	1	
8	<i>Eucalyptus</i>	2	
9	Pastagem (com árvores isoladas)	4	
10	Pastagem	4	

WGS: TL: (412.410); RA: (1.0); BR: (412.430); E: (688.930)



North

Meters



500.00

© 2014 Google

FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)
BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

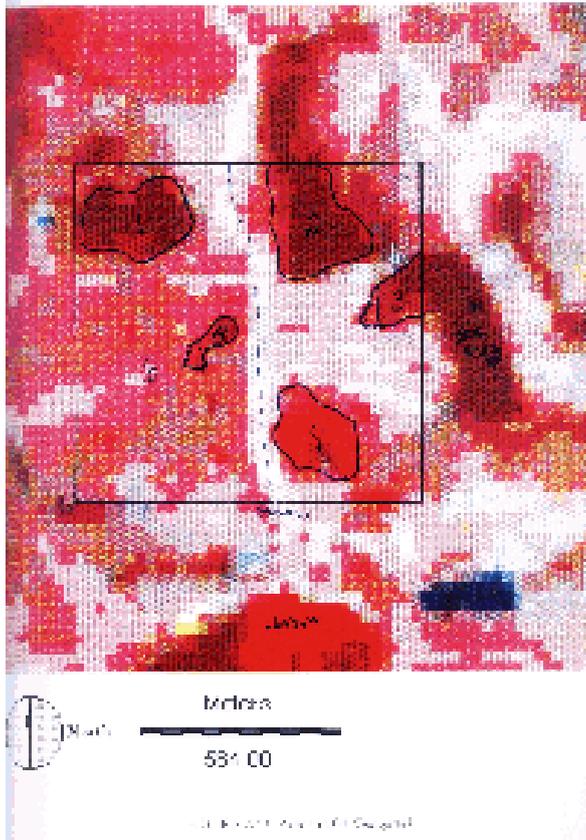
Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

AMOSTRA: 04

DATA: 17/01/97

NÚM.: 01/01

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
1	<i>Acácia (corte)</i>	3	
2	<i>Acácia (corte)</i>	3	
3	<i>Acácia</i>	3	
4	Nativa	1	
5	<i>Acácia</i>	3	
6	Pastagem	4	
7			
8			
9			
10			



FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)

BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

AMOSTRA: 05

DATA: 17/01/97

NÚM.: 01/02

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
1	Solo Exposto (ou milho)	5	
2	Pastagem	4	
3	Nativa	1	
4	Água	6	
5	Água	6	
6	Pastagem	4	
7	Nativa	1	
8	Pastagem	4	
9	Nativa	1	
10	Pastagem	4	

FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)
BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

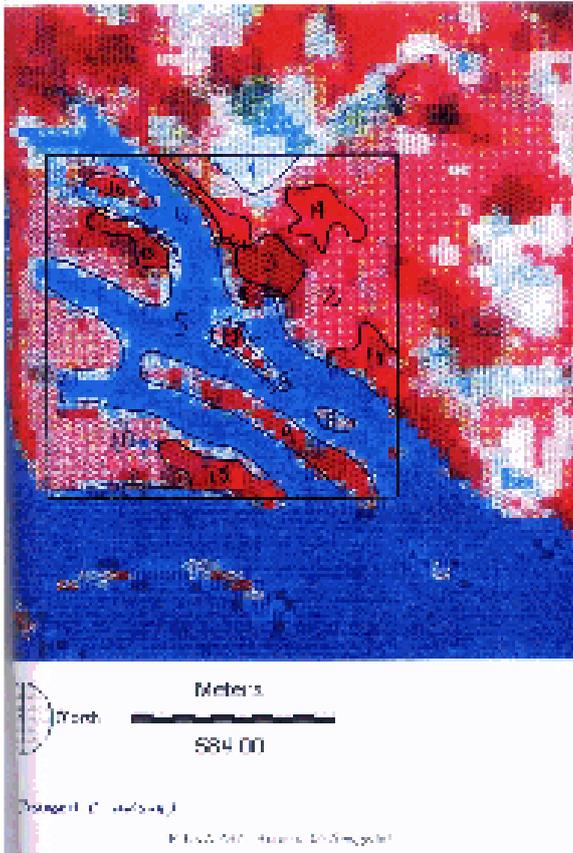
AMOSTRA: 05

DATA: 17/01/97

NÚM.: 02/02

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
11	Nativa	1	
12	Água (Rio Jacuí)	6	
13	Nativa	1	
14	Nativa	1	
15	Nativa	1	
16	Nativa	1	
17			
18			
19			
20			

05 TL (411.330,6.588.941) 100 (412.110,6.637.970)



FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)

BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

AMOSTRA: 06

DATA: 17/01/97

NÚM.: 01/01

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
1	<i>Acácia</i>	3	
2	Pastagem	4	
3	Pastagem	4	
4	Pastagem	4	
5	Pastagem	4	
6	Pastagem	4	
7	Pastagem	4	
8	Pastagem	4	
9	Pastagem	4	
10			

FACE TL: (13.400;7705.110) BR: (414.450;5.694.050)



FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)

BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

AMOSTRA: 07

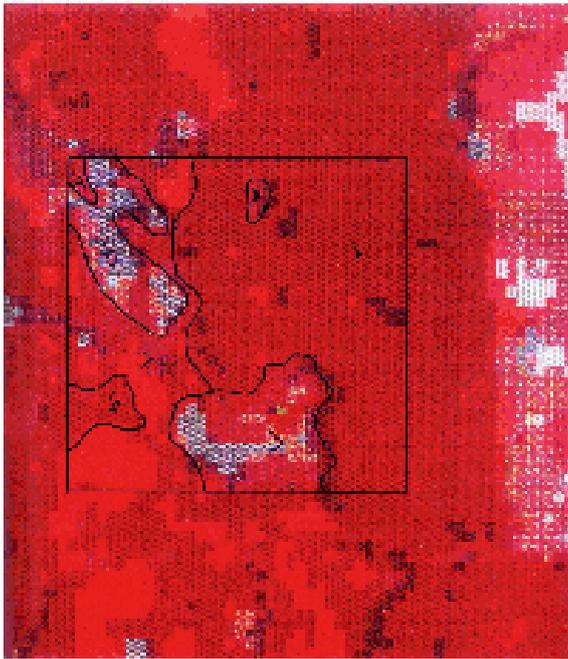
DATA: 03/02/97

NÚM.: 01/01

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
1	<i>Eucalyptus</i>	2	
2	Pastagem	4	
3	Pastagem	4	
4	Nativa	1	
5	Pastagem	4	
6	<i>Eucalyptus</i>	2	
7	Nativa	1	
8			
9			
10			

Dados obtidos de fotografias aéreas e mapas topográficos da Riocell.

45407 TL: (116.490, 6.687, 970) BR: (117.510, 6.686, 990)



North



U.S. Geological Survey of Oregon

FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)

BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

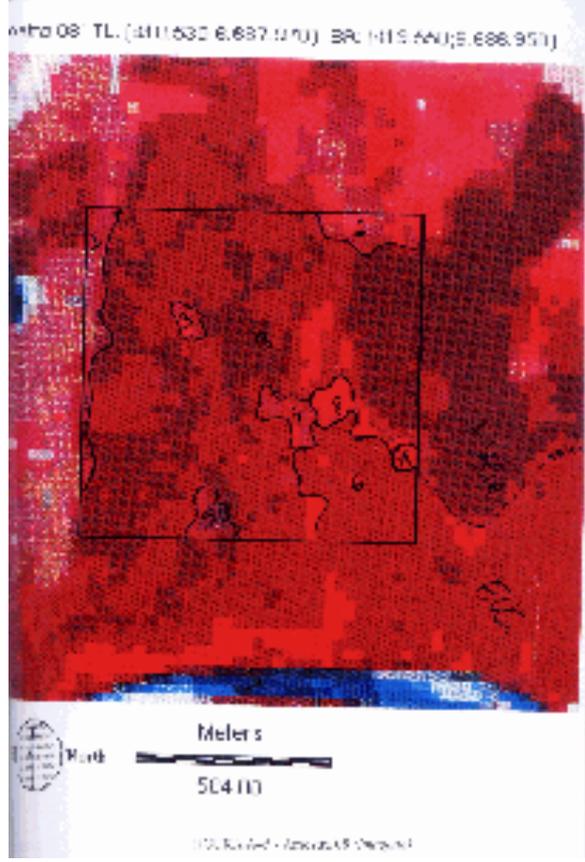
AMOSTRA: 08

DATA: 17/01/97

NÚM.: 01/01

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
1	Pastagem	4	
2	Pastagem	4	
3	Pastagem	4	
4	Pastagem	4	
5	Pastagem	4	
6	<i>Eucalyptus</i>	2	
7	Nativa	1	
8	Nativa	1	
9	<i>Acácia</i> (corte)	3	
10	Pastagem	4	

Campo 09: *Acácia* de várias idades ou de diferente qualidade de sementes; Há muitos restos de *Acácia* depositados pelo campo.



FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)
BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

AMOSTRA: 09

DATA: 03/02/97

NÚM.: 01/02

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
1	<i>Eucalyptus</i>	2	
2	<i>Eucalyptus</i>	2	
3	Nativa	1	
4	Pastagem	4	
5	<i>Eucalyptus</i>	2	
6	Pastagem	4	
7	<i>Eucalyptus</i>	2	
8	Nativa	1	
9	<i>Eucalyptus</i>	2	
10	<i>Eucalyptus</i>	2	

FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)
BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

AMOSTRA: 09

DATA: 03/02/97

NÚM.: 02/02

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
11	<i>Eucalyptus</i>	2	
12	<i>Eucalyptus</i>	2	
13	Pastagem	4	
14			
15			
16			
17			
18			
19			
20			

Dados obtidos de fotografias aéreas e mapas topográficos da Riocell.

FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)

BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

AMOSTRA: 10

DATA: 19/12/96

NÚM.: 01/02

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
1	<i>Acácia</i>	3	
2	Nativa	1	
3	Pastagem	4	
4	Pastagem	4	
5	Pastagem	4	
6	Pastagem	4	
7	Pastagem	4	
8	Pastagem	4	
9	Estrada (duas vias)	0	
10	Nativa	1	

FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)
BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

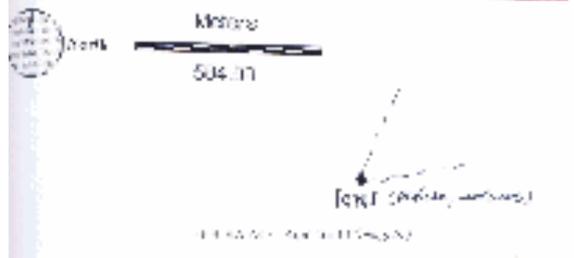
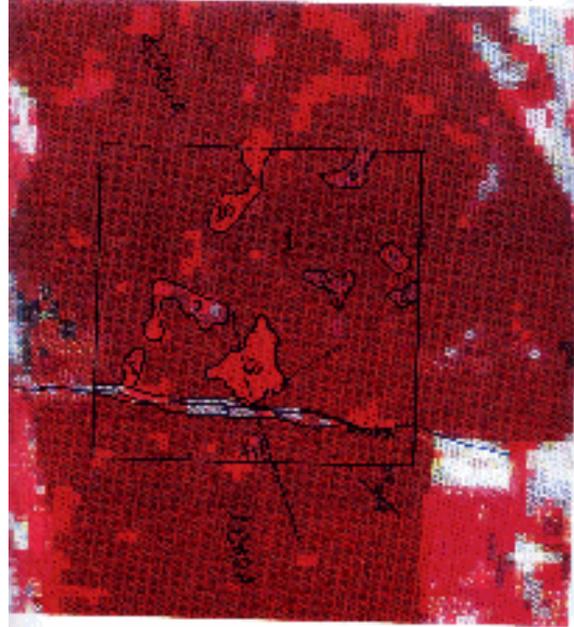
AMOSTRA: 10

DATA: 19/12/96

NÚM.: 02/02

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
11	Pastagem	4	
12			
13			
14			
15			
16			
17			
18			
19			
20			

Site 10 TL (412 410 8.692/190) ER (410 410 8.691.041)



FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)
BR (421.590; 6.684.910)

340 x 340 *pixels*

104,04 Km²

Pixel - 30 metros - *LANDSAT 5 - TM*

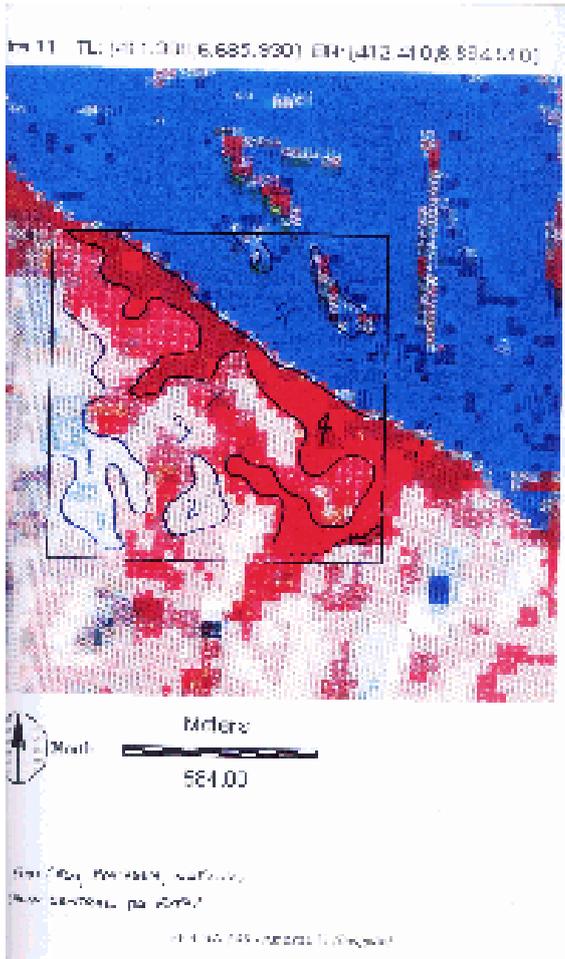
Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

AMOSTRA: 11

DATA: 03/02/97

NÚM.: 01/01

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
1	Solo Exposto (solo descoberto)	5	
2	Solo Exposto (solo descoberto)	5	
3	Pastagem	4	
4	Nativa	1	
5	Pastagem	4	
6	Pastagem	4	
7	Água	6	
8			
9			
10			



FORMULÁRIO DE VERIFICAÇÃO DE CAMPO

CPGSRM - CEPSRM - UFRGS

INVESTIGADORES: VIVIANE TODT, PEDRO A. MADRUGA, FLÁVIO DEPPE

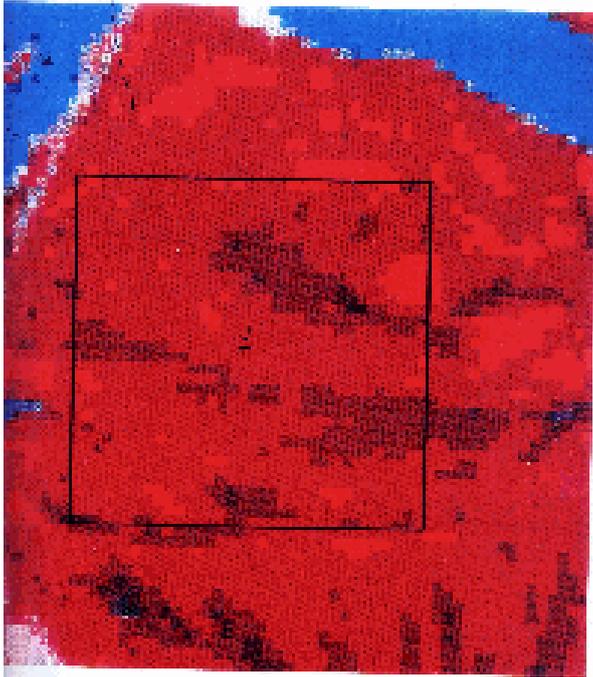
ÁREA DE ESTUDO

Coordenadas UTM: TL (411.390; 6.695.110)
 BR (421.590; 6.684.910)
 340 x 340 *pixels*
 104,04 Km²
Pixel - 30 metros - *LANDSAT 5 - TM*
 Órbita 221/81 quad. A - Rio Grande do Sul - Brasil

AMOSTRA: 12
DATA: 03/02/97
NÚM.: 01/01

CAMPO	USO DA TERRA	COD.	ÁREA (hectares)
1	Nativa	1	
2			
3			
4			
5			
6			
7			
8			
9			
10			

Site 12 TL (M 3.411) (S85.930) FR (M 4.400, S 584.110)



North

Meters



584.00

© 2000 AerialView.com

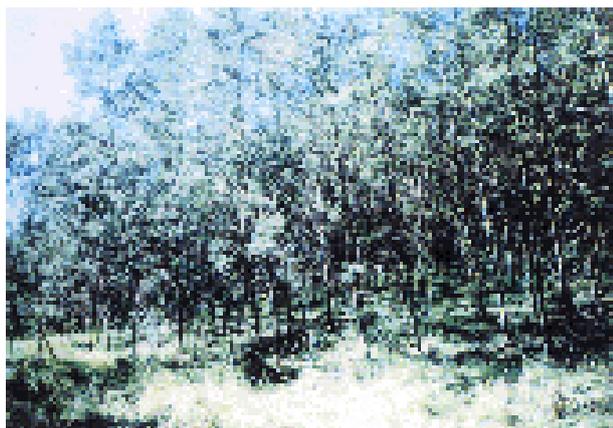


Fig. 1.1.1.1. - Foresta di conifere (pini) nel Parco Nazionale di Scaevola



Fig. 1.1.1.2. - Praterie aperte nel Parco Nazionale di Scaevola



Fig. 39.2. *Pinus strobus* - American
White Pine



Fig. 39.3. *Quercus alba* -
White Oak



2012.07.09 - 09. Pelti puolesta, joka on ajettu (muutama vuosi) ja on nyt hieman kalliimpi ja kalliimpi kuin ennen (100 €).



2012.07.09 - 10. Pelti puolesta, joka on ajettu (muutama vuosi) ja on nyt hieman kalliimpi ja kalliimpi kuin ennen (100 €).



Fig. 4.22: Forest landscape in a hill station in India



Fig. 4.23: Concrete bridge over a lake, Tangor, Karnataka, India



Fig. 14.14.11 - Avenida Niños
Enseñanza



Fig. 14.14.12 - Avenida Niños en la zona alagada de las montañas (alrededor del centro de enseñanza) (Zona del Fig. 14.11)

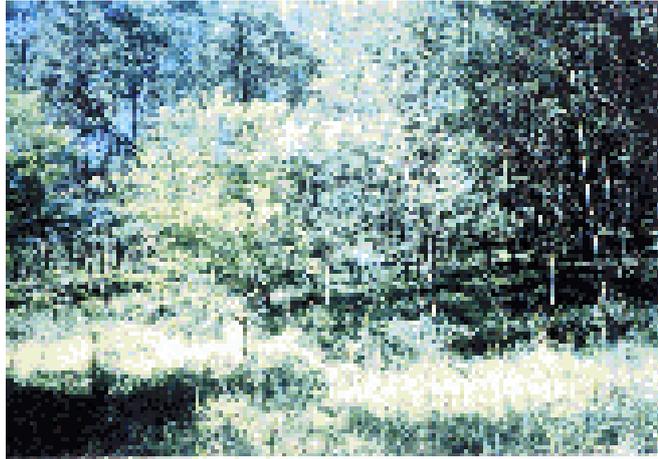


Fig. 10.24. Swamp forest along the Karkwaamokoi river, south of



Fig. 10.25. Forest along the Karkwaamokoi

ANEXO 11. Listagem do programa que gera números aleatórios entre 0 e 99 (NUMALE.C)

```

/*=====*/
/*= OBJETIVO:                                     =*/
/*= Selecionar 12 areas de amostragem (de 1Km2) aleatorias,      =*/
/*= entre 0 e 99.                                           =*/
/*=====*/

# include <stdio.h>
# include <time.h>
# include <stdlib.h>
# include <math.h>
# include <errno.h>
# include <string.h>
# include <ctype.h>
# include <stddef.h>

/* PARA GERACAO ALEATORIA DE VALORES.  */
/*=====*/
# define MAX      99
# define MIN      0
# define rnd()   (((double)rand()/(double)0x7fffffff)*(double)(MAX-
MIN))+ (double)(MIN))

/* DEFINICAO DE VARIAVEIS GLOBAIS */
/*=====*/
FILE *arq;

/* GERA VALORES RANDOMICOS.      */
/*=====*/
void gera_valores()
{
    int i, amostra;
    printf("\n\n");

    for(i=0; i<12; i++)
        { amostra=rnd();
          printf("AMOSTRA %d\t-> %d\n", i+1, amostra);
          fprintf(arq, "%d\n", amostra);
        }
}

/* APRESENTA TELA INICIAL  */
/*=====*/
void tela_inicial()
{char opcao;
printf("\n\n\n===== \n");
printf("          GERACAO DE NUMEROS ALEATORIOS ENTRE 0 E 99      \n");
printf("          P/ESCOLHA DE 12 AREAS DE 1KM X 1KM.              \n");
printf("===== \n");
}

/*      APRESENTA A TELA FINAL DO PROGRAMA.      */
/*=====*/
void tela_final()
{
printf("\n\n\n===== \n");
printf("MESTRANDA          : VIVIANE TODT\n");
printf("ORIENTADOR          : DR. PAULO M. ENGEL                      \n");
printf("CO-ORIENTADOR       : DR. PEDRO A. MADRUGA                    \n");
printf("APOIO               : DR. FLAVIO DEPPE                        \n\n");
printf("          1996                                               \n");
}

```

```

printf("=====\n\n");

/*  ABRE ARQUIVO.          */
/*=====*/
void abre_arq()
{  arq=fopen("num_aleat.doc","wb");
  if(arq==NULL)
  {
    printf("num_aleat.doc");
    printf("\nNome de arquivo invalido!  <ENTER>...\n");
    getchar();
    exit(1);
  }}

/*  FECHA ARQUIVO.        */
/*=====*/
void fecha_arq()
{
  if((fclose(arq))==EOF)
  {printf("num_aleat.doc");
   printf("Erro no fechamento do arquivo !!  <ENTER>...");
   getchar();
   exit(1);  }}

/*          MENU PRINCIPAL          */
/*=====*/
void main()
{
  int continua;

  tela_inicial();

  do {  abre_arq();
        gera_valores();
        fecha_arq();
        printf("\nGerar Novamente (s/n) ? ");
        continua=getchar();
        } while ((continua!='n')&&(continua!='N'));

  tela_final();}

```

Números Gerados:

```

34      85
90      66
51      75
39      57
60      86
77
92

```

ANEXO 12. Listagem do programa que implementa a RNA Multinível com BP (BPTANH.C)

```

/*=====*/
/*  OBJETIVO: */
/*    Implementar uma Rede Neural Multinivel com BACKPROPAGATION. */
/* */
/*  ARQUIVO DE ENTRADA: <nome_arq>.dat   Arquivo de dados p/ a RNA */
/*  ESTRUTURA DO ARQUIVO DE ENTRADA: */
/*    iteracoes criterio_parada coef_aprendizado */
/*    num_neu_entr num_neu_interm num_neu_sai */
/*    num_amostras */
/*    # */
/*    padrao1 saida_desej1 */
/*    # */
/*    padrao2 saida_desej2 */
/*    # */
/*    .... */
/*    # */
/*    padraon saida_desejn */
/*=====*/

# include <stdio.h>
# include <time.h>
# include <stdlib.h>
# include <math.h>
# include <errno.h>
# include <string.h>
# include <ctype.h>
# include <stddef.h>

/* PARA GERACAO ALEATORIA DE VALORES INICIAIS DOS PESOS */
/*=====*/
# define MAX      1.0
# define MIN      -1.0
# define rnd() (((double)rand()/(double)0x7fffffff)*(double)(MAX-
(MIN)))+(double)(MIN))

/* PARAMETROS QUE PODEM SER VARIADOS */
/*=====*/
# define MAX_NUM_ITER      500000
# define MAX_NUM_AMOSTRAS  1550
# define MAX_NUM_NEU_ENTR  10
# define MAX_NUM_NEU_INTERM  50
# define MAX_NUM_NEU_SAI   10

/* DEFINICAO DE VARIAVEIS GLOBAIS (LIDAS DO ARQUIVO .DAT) */
/*=====*/
int iteracoes;
double criterio_parada; /* erro maximo permitido */
double coef_aprend;
int num_amostras;
int num_neu_entr;
int num_neu_interm;
int num_neu_sai;
double padrao[MAX_NUM_AMOSTRAS][MAX_NUM_NEU_ENTR];
double saida_desej[MAX_NUM_AMOSTRAS][MAX_NUM_NEU_SAI];

```

```

/* DEFINICAO DE DEMAIS VARIAVEIS GLOBAIS */
/*=====*/
char nome_arq[15];
FILE *arq,*banda1,*banda2,*banda3,*banda4,*banda5,*banda7;
int num_bandas;
int b1,b2,b3,b4,b5,b7;

double wij[MAX_NUM_NEU_ENTR][MAX_NUM_NEU_INTERM];
double wjk[MAX_NUM_NEU_INTERM][MAX_NUM_NEU_SAI];
double bias_saida[MAX_NUM_NEU_SAI];
double bias_interm[MAX_NUM_NEU_INTERM];
double saida_obtida[MAX_NUM_NEU_SAI]; /* armazena a saida obtida com
cada um dos padroes fornecidos a rede */

/* As estruturas abaixo armazenam os valores sigmoidais de cada um
dos neuronios em cada uma das camadas */

double nivel_2[MAX_NUM_NEU_INTERM];
double nivel_3[MAX_NUM_NEU_SAI];

/***** HEADER DE
FUNCOES*****/
void inicializa_pesos();
void limpa_neuronios();
void tela_inicial();
void tela_final();
void apresenta_parametros();
void apresenta_amostras();
void imprime_pesos();
void resultados_saidas();
void abre_arq();
void fecha_arq();
void mensagem_erro();
void le_amostras();
void verifica_parametros();
void le_parametros();
void backpropagation();
void propaga();
void armazenar_pesos();
void resgatar_pesos();
double calc_erro_medio();
int verifica_erro();
void aprendizado();
void abre_arq_classif();
void abre_bandas();
void fecha_arq_classif();
void fecha_bandas();
int analisa_saida();
void reconhece_imagem();
void reconhecimento();
void main();

/***** FUNCOES *****/
/* INICIALIZA MATRIZES DE PESO COM VALORES RANDOMICOS. */
/*****/
void inicializa_pesos()
{ int i,j,k;

for(i=0;i<num_neu_entr;i++)

```

```

        for(j=0;j<num_neu_interm;j++)
            wij[i][j]=rnd();

    for(j=0;j<num_neu_interm;j++)
        for(k=0;k<num_neu_sai;k++)
            wjk[j][k]=rnd();

    for(k=0;k<num_neu_sai;k++)
        bias_saida[k]=rnd();

    for(j=0;j<num_neu_interm;j++)
        bias_interm[j]=rnd();}

/*    INICIALIZA ALGUMAS ESTRUTURAS QUE SERAO UTILIZADAS
POSTERIORMENTE.*/
/*****/
void limpa_neuronios()
{  int j,k;

    for(j=0;j<num_neu_interm;j++)
        nivel_2[j]=0.0;
    for(k=0;k<num_neu_sai;k++)
        nivel_3[k]=0.0;}

/*    APRESENTA A TELA INICIAL DO PROGRAMA.                                     */
/*****/
void tela_inicial()
{char opcao;

printf("\n\n\n\n=====\n");
printf("    REDE NEURAL MULTINIVEL COM BACKPROPAGATION          \n\n");
printf("    Treinamento:  Tangente Hiperbolica                  \n");
printf("=====\n\n");

do{ printf("\n\n Deseja informacoes (s/n) ?  ");
    opcao=getchar();
    }while((opcao!='S')&&(opcao!='N')&&(opcao!='s')&&(opcao!='n'));

if((opcao=='S')||(opcao=='s'))  {
printf("\n\n=====");
printf("\n    OBJETIVO:                                             ");
printf("\n\n    Implementar uma Rede Neural Multinivel com
BACKPROPAGATION.");
printf("\n\n\n\n    ESTRUTURA DO ARQUIVO DE TREINAMENTO:          ");
printf("\n\n    iteracoes criterio_parada coef_aprendizado          ");
printf("\n    num_neu_entr num_neu_interm num_neu_sai              ");
printf("\n    num_amostras                                          ");
printf("\n    #                                                       ");
printf("\n    padrao1 saida_desej1                                    ");
printf("\n    #                                                       ");
printf("\n    padrao2 saida_desej2                                    ");
printf("\n    #                                                       ");
printf("\n    ....                                                  ");
printf("\n    #                                                       ");
printf("\n    padraon saida_desejn                                     ");
printf("\n\n\n\n    RECEBE: <nome_arq.dat> / <nome_arq.pes>          ");
printf("\n    GERA  : <nome_arq.pes> / <nome_arq.res>              ");
printf("\n\n\n\n=====");
printf("\n\n\n\n");}/*IF*/
getchar();}

```

```

/*      APRESENTA A TELA FINAL DO PROGRAMA.                                          */
/*****
void tela_final()
{printf("\n\n\n=====\\n"
);
printf("MESTRANDA          : VIVIANE TODT\\n");
printf("ORIENTADOR          : DR. PAULO M. ENGEL\\n");
printf("          NOV/96\\n\n");

printf("=====\\n\n")
;};

/* APRESENTA PARAMETROS PARA A RNA.                                          */
/*****
void apresenta_parametros()
{ printf("\n\n\nINFORMACOES: \\n");
printf("=====\\n");
printf("ITERACOES          | %d \\n",iteracoes);
printf("CRITERIO DE PARADA   | %8.6f \\n",criterio_parada);
printf("COEF. APRENDIZADO    | %8.6f \\n",coef_aprend);
printf("NUM. DE AMOSTRAS     | %d \\n",num_amostas);
printf("NUM. NEUR. ENTRADA   | %d \\n",num_neu_entr);
printf("NUM. NEUR. INTERMED. | %d \\n",num_neu_interm);
printf("NUM. NEUR. SAIDA     | %d \\n",num_neu_sai);
printf("\\n\n\n <enter>");  getchar(); }

/* APRESENTA AMOSTRAS.                                          */
/*****
void apresenta_amostas()
{ int i,k,l;

printf("\\n\n\n\n");
printf("          AMOSTRAS :\\n\n\n");
printf("ENTRADAS          E          SAIDAS DESEJADAS\\n");
printf("-----\\n");

/* IMPRIME PADROES E SAIDAS DESEJADAS */
for(l=0;l<num_amostas;l++)
{ for(i=0;i<num_neu_entr;i++)
printf("%lf\\t",padrao[l][i]);

/* IMPRIME SAIDA CORRESPONDENTE AO PADRAO */
printf("| ");

for(k=0;k<num_neu_sai;k++)
printf("%3.1lf\\t",saida_desej[l][k]);

printf("\\n");  }/*FOR i*/
printf("\\n\n\n <enter>");  getchar();}

/* IMPRIME OS PESOS GERADOS ALEATORIAMENTE.                                          */
/*****
void imprime_pesos()
{int i,j,k;

printf("\\n\n\n\nGERACAO ALEATORIA DE PESOS - Wij");
printf("\\n-----\\n");

```

```

for(i=0;i<num_neu_entr;i++)
  {printf("neu.entr. %d |",i);
  for(j=0;j<num_neu_interm;j++)
    printf("%8.6f      ",wij[i][j]);
  printf("\n"); } /*FOR i*/

printf("\n\nGERACAO ALEATORIA DE PESOS - Wjk");
printf("\n-----\n");
for(j=0;j<num_neu_interm;j++)
  {printf("neu.interm. %d |",j);
  for(k=0;k<num_neu_sai;k++)
    printf("%8.6f      ",wjk[j][k]);
  printf("\n"); } /*FOR j*/

printf("\n\n\n  <enter>"); getchar();
printf("\n\n  <aguarde>");}

/* IMPRIME A SAIDA OBTIDA DA REDE APOS O FORNECIMENTO DE CADA UMA      */
/* DAS AMOSTRAS.                                                         */
/*****
void resultados_saidas()
{int i,l;

printf("\n\n\n\n");
printf("      =====\n");
printf("      RESULTADOS OBTIDOS COM A RNA:\n");
printf("      =====\n\n\n");
printf("ENTRADAS          E          SAIDAS OBTIDAS\n");
printf("-----\n");

/* IMPRIME PADROES E SAIDAS DESEJADAS */
for(i=0;i<num_amstras;i++)
  { for(l=0;l<num_neu_entr;l++)
    printf("%lf      ",padrao[i][l]);

/* IMPRIME SAIDA OBTIDA CORRESPONDENTE AO PADRAO */
printf("\t|");
propaga(i);
for(l=0;l<num_neu_sai;l++)
  printf(" %lf      ",saida_obtida[l]);

printf("\n"); } /*FOR i*/ }

/* ABRE ARQUIVO.                                                         */
/*****
void abre_arq(opcao)
int opcao;
{ printf("\n\n\n");

if(opcao==0) /* le arq. de amostras */
  { printf("NOME DO ARQUIVO DE AMOSTRAS (.dat): ");
  gets(nome_arq);
  arq=fopen(nome_arq,"rb"); }

if(opcao==1) /* le arq. de pesos */
  { printf("ARQUIVO DE PESOS PARA LEITURA (.pes): ");
  gets(nome_arq);
  arq=fopen(nome_arq,"rb"); }

```

```

if(opcao==2) /* grava arq. com pesos */
{printf("\n\n\n ARQUIVO DE PESOS PARA GRAVACAO (.pes): ");
  gets(nome_arq);
  arq=fopen(nome_arq,"wb"); }

if(arq==NULL)
{ /* printf(nome_arq);*/
  printf("\n Nome de arquivo invalido!\n\n\n ");
  tela_final();
  exit(); }}

/* FECHA ARQUIVO. */
/*****/
void fecha_arq()
{ if((fclose(arq))==EOF) /* fechamento do arquivo de imagem */
  { printf(nome_arq);
    printf("Erro no fechamento do arquivo !! ");
    exit(0); }}

/* EXIBE MENSAGEM DE ERRO NA TELA E ENCERRA PROGRAMA. */
/*****/
void mensagem_erro()
{ printf("\n VERIFIQUE ARQUIVO: ");
  printf(nome_arq);
  printf("\n\n");
  tela_final();
  exit(1); }

/* LE AMOSTRAS E SAIDAS DESEJADAS CORRESPONDENTES, DE ARQUIVO .DAT */
/*****/
void le_amostras()
{ int i,l,k;
  char aux;
  double nivel_cinza;
  int valor_classe;
  double constante=(2.0/255.0);

  for(l=0;l<num_amostras;l++)
  { fscanf(arq,"%c\n",&aux);
    if(aux!='#')
    {printf("\n\n\n ERRO SINAL SEPARADOR APOS PARAMETROS");
      mensagem_erro(); }

  for(i=0;i<num_neu_entr;i++)
  { fscanf(arq,"%lf",&nivel_cinza);
    printf("%lf ",nivel_cinza);

    /*NORMALIZA ENTRADAS ENTRE -1 E 1*/
    padrao[l][i]=(constante*nivel_cinza)-1.0; }

  fscanf(arq,"%d",&valor_classe); /* PARA ATEH 6 CLASSES */
  switch(valor_classe)
  { case 1:{ saida_desej[l][0]=1;
            saida_desej[l][1]=-1;
            saida_desej[l][2]=-1;
            saida_desej[l][3]=-1;
            saida_desej[l][4]=-1;
            saida_desej[l][5]=-1;
          }
  }
}

```

```

        break; /* ACACIA*/    }

    case 2:{ saida_desej[1][0]=-1;
             saida_desej[1][1]=1;
             saida_desej[1][2]=-1;
             saida_desej[1][3]=-1;
             saida_desej[1][4]=-1;
             saida_desej[1][5]=-1;
             break; /* AGUA */    }

    case 3:{ saida_desej[1][0]=-1;
             saida_desej[1][1]=-1;
             saida_desej[1][2]=1;
             saida_desej[1][3]=-1;
             saida_desej[1][4]=-1;
             saida_desej[1][5]=-1;
             break; /* EUCALIPTUS */    }

    case 4: {saida_desej[1][0]=-1;
             saida_desej[1][1]=-1;
             saida_desej[1][2]=-1;
             saida_desej[1][3]=1;
             saida_desej[1][4]=-1;
             saida_desej[1][5]=-1;
             break; /* NATIVA */    }

    case 5: {saida_desej[1][0]=-1;
             saida_desej[1][1]=-1;
             saida_desej[1][2]=-1;
             saida_desej[1][3]=-1;
             saida_desej[1][4]=1;
             saida_desej[1][5]=-1;
             break; /* PASTAGEM */    }

    case 6: {saida_desej[1][0]=-1;
             saida_desej[1][1]=-1;
             saida_desej[1][2]=-1;
             saida_desej[1][3]=-1;
             saida_desej[1][4]=-1;
             saida_desej[1][5]=1;
             break; /* SOLOS DESCOBERTOS */    } } /*CASE*/
fscanf(arq, "\n"); /*P/MUDAR DE LINHA*/    }

/* VERIFICA CONSISTENCIA DE PARAMETROS OBTIDOS NO ARQUIVO .DAT    */
/*****/
void verifica_parametros()
{if((iteracoes<1)|| (iteracoes>MAX_NUM_ITER))
  { printf("\n\n\n NUMERO DE ITERACOES FORA DO LIMITE [1;%d] !",
MAX_NUM_ITER);
  mensagem_erro();    }
  if((criterio_parada<0)|| (criterio_parada>1))
  {printf("\n\n\n CRITERIO DE PARADA FORA DO LIMITE [0.000001;1]
!");
  mensagem_erro();    }

  if((coef_aprend<0)|| (coef_aprend>1))
  {printf("\n\n\n COEFICIENTE DE APRENDIZADO FORA DO LIMITE [0;1]
!");
  mensagem_erro();    }
}

```

```

        if((num_neu_entr<1)|| (num_neu_entr>MAX_NUM_NEU_ENTR))
        {
            printf("\n\n\n NUM. NEUR. ENTRADA FORA DO LIMITE
[1;%d]",
MAX_NUM_NEU_ENTR);
            mensagem_erro();        }

        if((num_neu_interm<1)|| (num_neu_interm>MAX_NUM_NEU_INTERM))
        {printf("\n\n\n NUM. NEUR. INTERM. FORA DO LIMITE [1;%d]",
MAX_NUM_NEU_INTERM);
            mensagem_erro();        }

        if((num_neu_sai<1)|| (num_neu_sai>MAX_NUM_NEU_SAI))
        {printf("\n\n\n NUM. NEUR. SAIDA FORA DO LIMITE [1;%d]",
MAX_NUM_NEU_SAI);
            mensagem_erro();        }

        if((num_amostras<1)|| (num_amostras>MAX_NUM_AMOSTRAS))
        {printf("\n\n\n NUM. AMOSTRAS FORA DO LIMITE [1;%d]",
MAX_NUM_AMOSTRAS);
            mensagem_erro();        }}

/* LE PARAMETROS DE APRENDIZAGEM PARA A REDE NEURAL DE ARQUIVO .DAT */
/*****
void le_parametros()
{int i,l;
  abre_arq(0); /* Abre arquivo de amostras. */
  fscanf(arq,"%d %lf %lf\n",&iteracoes,&critério_parada,&coef_aprend);
  fscanf(arq,"%d %d %d\n",&num_neu_entr,&num_neu_interm,&num_neu_sai);
  fscanf(arq,"%d\n",&num_amostras);
  verifica_parametros();
  le_amostras();
  fecha_arq(arq);}

/*ESTA FUNCAO REALIZA A ALTERACAO RETROGADA DO ERRO, ALTERANDO AS MA-
/* TRIZES DE PESO.
/*****
void backpropagation(n_padrao)
int n_padrao;
{ int i,j,k;
  double erro_escond[MAX_NUM_NEU_INTERM]; /*termo de erro da camada
escondida para cada neuronio p/n_padrao */

double erro_saida[MAX_NUM_NEU_SAI]; /* termo de erro da camada de
saida para cada neuronio p/n_padrao */

double atualiz_peso,somatorio,novo_peso_bias;

/* CALCULO DO TERMO DE ERRO P/ UNIDADES DE SAIDA
===== */
for(k=0;k<num_neu_sai;k++)
  erro_saida[k] = (saida_desej[n_padrao][k] - saida_obtida[k])
* (1.0-(pow(saida_obtida[k],2.0)));

```

```

/* CALCULO DO TERMO DE ERRO P/ UNIDADES ESCONDIDAS
===== */
for(j=0;j<num_neu_interm;j++)
{ for(somatorio=0.0,k=0;k<num_neu_sai;k++)
    somatorio += (erro_saida[k] * wjk[j][k]);

    erro_escond[j]=(1.0-(pow(nivel_2[j],2.0))) * somatorio; }

/* ATUALIZACAO DOS PESOS DA CAMADA DE SAIDA
=====*/
for(j=0;j<num_neu_interm;j++)
for(k=0;k<num_neu_sai;k++)
{ atualiz_peso= coef_aprend * erro_saida[k] * nivel_2[j];
  wjk[j][k] += atualiz_peso; }

/* ATUALIZACAO DOS PESOS DA CAMADA ESCONDIDA
=====*/
for(i=0;i<num_neu_entr;i++)
for(j=0;j<num_neu_interm;j++)
{ atualiz_peso= coef_aprend * erro_escond[j] *
padrao[n_padrao][i];
  wij[i][j] += atualiz_peso; }

/* ATUALIZACAO DOS PESOS DOS BIAS
=====*/
for(k=0;k<num_neu_sai;k++)
{ novo_peso_bias= coef_aprend * erro_saida[k];
  bias_saida[k]+= novo_peso_bias; }

for(j=0;j<num_neu_interm;j++)
{ novo_peso_bias= coef_aprend * erro_escond[j];
  bias_interm[j] += novo_peso_bias; }}

/*ESTA FUNCAO RECEBE COMO PARAMETRO O INDICE DO PADRAO QUE SERA PROPAGA-
*/
/*GADO ATE O FINAL DA REDE NEURAL. */
/*****/
void propaga(n_padrao)
int n_padrao;
{ double aux;
  int i,j,k;

  limpa_neuronios();
for(j=0;j<num_neu_interm;j++)
  {for(i=0;i<num_neu_entr;i++)
    nivel_2[j]+=(padrao[n_padrao][i]*wij[i][j]);

    aux=nivel_2[j]+bias_interm[j];
    nivel_2[j]=(1.0-exp(-2.0*aux))/(1.0+exp(-2.0*aux));
    /* armazena a saida tanh dos neuronios */
    /* do nivel intermediario */ }

for(k=0;k<num_neu_sai;k++)
{ for(j=0;j<num_neu_interm;j++)
  nivel_3[k]+=(nivel_2[j]*wjk[j][k]);

  aux=nivel_3[k]+bias_saida[k];

```

```

        nivel_3[k]=(1.0-exp(-2.0*aux))/(1.0+exp(-2.0*aux));
                /* armazena a saida tanh do(s) neuronio(s) */
                /* do nivel de saida */

        saida_obtida[k]=nivel_3[k];    }}

/*   ARMAZENA OS PESOS OBTIDOS PELA FASE DE APRENDIZADO DA RNA.   */
/*****
void armazenar_pesos()
{  int i,j,k;
   abre_arq(2);
   for(i=0;i<num_neu_entr;i++)
       for(j=0;j<num_neu_interm;j++)
           fprintf(arq,"%lf ",wij[i][j]);

   for(j=0;j<num_neu_interm;j++)
       for(k=0;k<num_neu_sai;k++)
           fprintf(arq,"%lf ",wjk[j][k]);

   for(j=0;j<num_neu_interm;j++)
       fprintf(arq,"%lf ",bias_interm[j]);

   for(k=0;k<num_neu_sai;k++)
       fprintf(arq,"%lf ",bias_saida[k]);

   fecha_arq();}

/*   RESGATA OS PESOS OBTIDOS PELA FASE DE APRENDIZADO DA RNA.   */
/*****
void resgatar_pesos()
{  int i,j,k;
   abre_arq(1);
   for(i=0;i<num_neu_entr;i++)
       for(j=0;j<num_neu_interm;j++)
           fscanf(arq,"%lf ",&wij[i][j]);

   for(j=0;j<num_neu_interm;j++)
       for(k=0;k<num_neu_sai;k++)
           fscanf(arq,"%lf ",&wjk[j][k]);

   for(j=0;j<num_neu_interm;j++)
       fscanf(arq,"%lf ",&bias_interm[j]);

   for(k=0;k<num_neu_sai;k++)
       fscanf(arq,"%lf ",&bias_saida[k]);

   fecha_arq();}

/*   CALCULA O ERRO MEDIO QUADRADO.   */
/*****
double calc_erro_medio()
{  double erro_medio,som_erro;
   int l,k;

   for(erro_medio=0.0,l=0;l<num_amostras;l++)
       {propaga(l);

        for(k=0,som_erro=0.0;k<num_neu_sai;k++)

```

```

        som_erros+=pow((saida_desej[l][k]-saida_obtida[k]),2.0);

        erro_medio+=som_erros * 0.5;    }

    return(erro_medio/(double)num_amostras);}

/* VERIFICA SE CADA AMOSTRA POSSUI UM ERRO DE SAIDA <= AO ERRO ESTIPU-
*/ LADO.
/*
/*****
int verifica_erro()
{   double erro_medio,som_erros;
    int l,k;

        for(l=0;l<num_amostras;l++)
            {   propaga(l);

                for(k=0,som_erros=0.0;k<num_neu_sai;k++)
                    som_erros+=pow((saida_desej[l][k]-saida_obtida[k]),2.0);

                erro_medio=som_erros * 0.5;

                if(erro_medio>critério_parada) return(0); }

    return(1);}

/* GERENCIA O APRENDIZADO DA RNA.
*/
/*****
void aprendizado()
{   int l,k;
    int termino=0;
    int iter=0;

        printf("\n\n\n----- APRENDIZADO -----");
        le_parametros();
        apresenta_parametros();
        apresenta_amostras();
        inicializa_pesos();
        imprime_pesos();

        do {for(l=0;l<num_amostras;l++) {
            propaga(l);
            backpropagation(l);    }

            if(verifica_erro()) /*RETORNA 1 SE ERRO com todos padroes
<=ESTIPULADO */
                termino=1;

            else iter++;
        }while((termino!=1)&&(iter<iteracoes));

        resultados_saidas();
        imprime_pesos();

        if(termino==0)
            {printf("\n\n\n APRENDIZAGEM NAO REALIZADA !");
              printf("\n\n    Todas as amostras, individualmente, nao apresentaram
um
                                                    erro");

```

```

printf("\n de saida menor ou igual ao criterio de parada
estipulado."); }

else printf("\n\n\n SUCESSO !!! APRENDIZAGEM REALIZADA.");

printf("\n\n TOTAL DE ITERACOES REALIZADAS: %d",iter);
printf("\n\n ERRO MEDIO ALCANCADO: %lf",calc_erro_medio());
armazenar_pesos();
printf("\n\n\n----- FIM APRENDIZADO -----");}

/* ABRE ARQUIVO DE CLASSIFICACAO (RESULTADO FINAL) */
/*****
void abre_arq_classif()
{ printf("CRIACAO DE ARQUIVO DE CLASSIFICACAO: J2.CLA ");
  arq=fopen("j2.cla", "wb");
  if(arq==NULL) {
    printf("\n Nome de arquivo invalido!\n\n\n ");
    tela_final(); exit(0); }}

/* ABRE BANDAS. */
/*****
void abre_bandas()
{ printf("\nQTDE BANDAS: %d",num_neu_entr);
  if(b1==1)
  { printf("BANDA 1: J2_1_N.IMG ");
    banda1=fopen("j2_1_n.img", "rb");
    if(banda1==NULL) {
      printf("\n Nome de arquivo de banda invalido!\n\n\n ");
      tela_final(); exit(0); }
    }/*BANDA 01*/

  if(b2==1)
  {printf("BANDA 2: J2_2_N.IMG ");
    banda2=fopen("j2_2_n.img", "rb");
    if(banda2==NULL)
      {printf("\n Nome de arquivo de banda invalido!\n\n\n ");
        tela_final(); exit(0); } }/*BANDA 02*/

  if(b3==1)
  {printf("BANDA 3: J2_3_N.IMG ");
    banda3=fopen("j2_3_n.img", "rb");
    if(banda3==NULL)
      {printf("\n Nome de arquivo de banda invalido!\n\n\n ");
        tela_final(); exit(0); } }/*BANDA 03*/

  if(b4==1)
  {printf("BANDA 4: J2_4_N.IMG ");
    banda4=fopen("j2_4_n.img", "rb");
    if(banda4==NULL)
      {printf("\n Nome de arquivo de banda invalido!\n\n\n ");
        tela_final(); exit(0); } }/*BANDA 04*/

  if(b5==1)
  {printf("BANDA 5: J2_5_N.IMG ");
    banda5=fopen("j2_5_n.img", "rb");
    if(banda5==NULL)
      {printf("\n Nome de arquivo de banda invalido!\n\n\n ");
        tela_final(); exit(0); } }/*BANDA 05*/

```

```

if(b7==1)
{printf("BANDA 7: J2_7_N.IMG ");
 banda7=fopen("j2_7_n.img","rb");
 if(banda7==NULL)
 {printf("\n Nome de arquivo de banda invalido!\n\n\n ");
  tela_final(); exit(0); } }/*BANDA 07*/
}

/* FECHA ARQUIVO DE CLASSIFICACAO.          */
/*****/
void fecha_arq_classif()
{ if((fclose(arq))==EOF)
  { printf("J2.CLA");
    printf("Erro no fechamento do arquivo !! ");
    exit(0); }}

/* FECHA BANDAS.                          */
/*****/
void fecha_bandas()
{ if(b1==1)
  if((fclose(banda1))==EOF)
  { printf("BANDA 1: J2_1_N.IMG");
    printf("Erro no fechamento do arquivo !! ");
    exit(0); }

  if(b2==1)
  if((fclose(banda2))==EOF)
  { printf("BANDA 2: J2_2_N.IMG");
    printf("Erro no fechamento do arquivo !! ");
    exit(0); }

  if(b3==1)
  if((fclose(banda3))==EOF)
  { printf("BANDA 3: J2_3_N.IMG");
    printf("Erro no fechamento do arquivo !! ");
    exit(0); }

  if(b4==1)
  if((fclose(banda4))==EOF)
  { printf("BANDA 4: J2_4_N.IMG");
    printf("Erro no fechamento do arquivo !! ");
    exit(0); }

  if(b5==1)
  if((fclose(banda5))==EOF)
  { printf("BANDA 5: J2_5_N.IMG");
    printf("Erro no fechamento do arquivo !! ");
    exit(0); }

  if(b7==1)
  if((fclose(banda7))==EOF)
  { printf("BANDA 7: J2_7_N.IMG");
    printf("Erro no fechamento do arquivo !! ");
    exit(0); }}

```

```

/* GERENCIA A ETAPA DE RECONHECIMENTO DE TODA A IMAGEM PELA RNA.      */
/*****/
int analisa_saida()
{ int classe,k,l,controle;

  for(k=0;k<num_neu_sai;k++)
    if(saida_obtida[k]<0.0)
      saida_obtida[k]=-1.0;
    else
      saida_obtida[k]=1.0;

  for(k=0,controle=0,classe=0;((k<num_neu_sai)&&(controle!=1));k++)
    if(saida_obtida[k]==1.0)
      { for(l=k+1;((l<num_neu_sai)&&(controle!=1));l++)
        if(saida_obtida[l]==1.0)
          { controle=1;
            classe=0; }

        if(controle==0)
          classe=k+1;/* POIS O K COMECA EM ZERO*/ }
  return(classe);}

/* GERENCIA A ETAPA DE RECONHECIMENTO DE TODA A IMAGEM PELA RNA.      */
/*****/
void reconhece_imagem()
{ double constante=(2.0/255.0);
  unsigned char cd;
  char aux;
  int classe,entr;
  int i,tam_imag;

  tam_imag=115600; /*ATUALIZAR!!!!!! */
  b1=b2=b3=b4=b5=b7=0;
  entr=0;

  printf("\nUTILIZAR BANDA NA CLASSIFICACAO ATUAL (s/n)?");

/*BANDA 01*/
do{printf("\nBanda 1: ");
  scanf("%c",aux);
  }while((aux!='s')&&(aux!='S')&&(aux!='n')&&(aux!='N'));

  if((aux=='s')|| (aux=='S')) b1=1;

/*BANDA 02*/
do{printf("\nBanda 2: ");
  scanf("%c",aux);
  }while((aux!='s')&&(aux!='S')&&(aux!='n')&&(aux!='N'));

  if((aux=='s')|| (aux=='S')) b2=1;

/*BANDA 03*/
do {printf("\nBanda 3: ");
  scanf("%c",aux);
  }while((aux!='s')&&(aux!='S')&&(aux!='n')&&(aux!='N'));

  if((aux=='s')|| (aux=='S')) b3=1;

/*BANDA 04*/

```

```

do {printf("\nBanda 4: ");
    scanf("%c",aux);
    }while((aux!='s')&&(aux!='S')&&(aux!='n')&&(aux!='N'));

if((aux=='s')||(aux=='S')) b4=1;

/*BANDA 05*/
do {printf("\nBanda 5: ");
    scanf("%c",aux);
    }while((aux!='s')&&(aux!='S')&&(aux!='n')&&(aux!='N'));

if((aux=='s')||(aux=='S')) b5=1;

/*BANDA 07*/
do {printf("\nBanda 7: ");
    scanf("%c",aux);
    }while((aux!='s')&&(aux!='S')&&(aux!='n')&&(aux!='N'));

if((aux=='s')||(aux=='S')) b7=1;

printf("\n\nBANDAS A UTILIZAR: b1(%d) b2(%d) b3(%d) b4(%d) b5(%d)
b7(%d)",b1,b2,b3,b4,b5,b7);

abre_arq_classif();
abre_bandas();

printf("\nTAMANHO DA IMAGEM: %d",tam_imag);

for(i=0;i<tam_imag;i++)
{if(b1==1)
    {fread(&cd,sizeof(cd),1,banda1);
    padrao[0][entr]=constante*(double)cd-1.0; /*NORMALIZANDO*/
    entr++; }

if(b2==1)
    {fread(&cd,sizeof(cd),1,banda2);
    padrao[0][entr]=constante*(double)cd-1.0;
    entr++; }

if(b3==1)
    {fread(&cd,sizeof(cd),1,banda3);
    padrao[0][entr]=constante*(double)cd-1.0;
    entr++;}

if(b4==1)
    {fread(&cd,sizeof(cd),1,banda4);
    padrao[0][entr]=constante*(double)cd-1.0;
    entr++; }

if(b5==1)
    {fread(&cd,sizeof(cd),1,banda5);
    padrao[0][entr]=constante*(double)cd-1.0;
    entr++; }

if(b7==1)
    {fread(&cd,sizeof(cd),1,banda7);
    padrao[0][entr]=constante*(double)cd-1.0;
    entr++; }

propaga(0);
classe=analisa_saida();

```

```

        fprintf(arq, "%d ", classe); }

    fecha_bandas();
    fecha_arq_classif();}

/* GERENCIA A ETAPA DE RECONHECIMENTO DA RNA.                                     */
/*****                                                                           */
void reconhecimento()
{ int l;
  char opcao;

  printf("\n\n\n----- RECONHECIMENTO -----");
  le_parametros();
  apresenta_parametros();
  apresenta_amostras();
  resgatar_pesos();
  resultados_saidas(); /*RECONHECE ARQ.DE AMOSTRAS*/

  do{printf("\n\n Deseja Reconhecer TODA a imagem (s/n) ?  ");
    opcao=getchar();
    }while((opcao!='S')&&(opcao!='N')&&(opcao!='s')&&(opcao!='n'));
  getchar();

  if((opcao=='S')|| (opcao=='s'))
    reconhece_imagem();

  printf("\n\n\n----- FIM RECONHECIMENTO -----");}

/* MENU PRINCIPAL.                                                               */
/*****                                                                           */
void menu_principal()
{ int continua;
  int fim=0;

  do{ printf("\n\n\n          Menu\n");
    printf("          ----\n\n");
    printf("          1- APRENDIZADO  \n");
    printf("          2- RECONHECIMENTO\n");
    printf("          3- FIM          \n");
    continua='0';
    while ((continua!='1')&&(continua!='2')&&(continua!='3'))
      { printf("\n\n Opcao:  ");
        continua=getchar();  getchar(); }

    switch(continua){
      case '1': { aprendizado(); break; }
      case '2': { reconhecimento(); break;}
      case '3': { fim=1; tela_final(); }}/*SWITCH*/
    }while(fim!=1);}

/* PROGRAMA PRINCIPAL                                                           */
/*****                                                                           */
void main()
{ tela_inicial();
  menu_principal();}

```

ANEXO 13. Listagem do programa que calcula a quantidade de acertos e erros em imagens classificadas (ACURACIA.C)

```

/*=====*/
/* OBJETIVO: */
/* Calcula a acuracia da classificacao obtida. */
/*=====*/

# include <stdio.h>
# include <time.h>
# include <stdlib.h>
# include <math.h>
# include <errno.h>
# include <string.h>
# include <ctype.h>
# include <stddef.h>

# define MAX_COLUNA 136
# define MAX_LINHA 102
# define MAX_CLASSE 7

/* DEFINICAO DE VARIAVEIS GLOBAIS (LIDAS DO ARQUIVO .DAT) */
/*=====*/
int linha,coluna,classe,num_pontos;

/* DEFINICAO DE DEMAIS VARIAVEIS GLOBAIS */
/*=====*/
FILE *arq_aux,*arq_pontos,*arq_imagem,*fopen();
char nome_arq_pontos[15],nome_arq_imagem[15];
unsigned char matriz[MAX_LINHA][MAX_COLUNA];
int vclasse[MAX_CLASSE];

/***** HEADER DE FUNCOES*****/
void limpa_matriz();
void le_imagem();
void abre_arq();
void fecha_arq();
void le_pontos();
void main();

/***** FUNCOES *****/

/* INICIALIZA ALGUMAS ESTRUTURAS QUE SERAO UTILIZADAS
POSTERIORMENTE.*/
/******/
void limpa_matriz()
{
    int j,k;

    for(j=0;j<MAX_LINHA;j++)
        for(k=0;k<MAX_COLUNA;k++)
            matriz[j][k]=0;

    for(j=0;j<7;j++)
        vclasse[j]=0;
}

/* LE IMAGEM. */
/******/
void le_imagem()
{
    int j,k;

    for(j=0;j<MAX_LINHA;j++)
        for(k=0;k<MAX_COLUNA;k++)

```

```

        fread(&matriz[j][k], sizeof(matriz[j][k]), 1, arq_imagem);
    }

/*  ABRE ARQUIVO DE PONTOS.
*/
/*****
/
void abre_arq(opcao)
int opcao;
{
    if(opcao==0)
    {
        printf("\n Arquivo de Pontos (c/extensao): ");
        gets(nome_arq_pontos);
        arq_pontos=fopen(nome_arq_pontos, "rb");
        if(arq_pontos==NULL)
        {
            printf("\n Nome de arquivo de pontos invalido!\n\n\n ");
            exit(0);
        }
    }

    if(opcao==1)
    {
        printf("\n Arquivo de Imagem Classificada (c/extensao): ");
        gets(nome_arq_imagem);
        arq_imagem=fopen(nome_arq_imagem, "rb");
        if(arq_imagem==NULL)
        {
            printf("\n Nome de arquivo de imagem invalido!\n\n\n ");
            exit(0);
        }
    }

    if(opcao==2)
    {
        arq_aux=fopen("auxiliar.dat", "wt");
        if(arq_aux==NULL)
        {
            printf("\n Nome de arquivo auxiliar invalido!\n\n\n ");
            exit(0);
        }
    }
}

/*  FECHA ARQUIVO.
*/
/*****
void fecha_arq(opcao)
int opcao;
{
    if(opcao==0)
        if((fclose(arq_pontos))==EOF)
        {
            printf("Erro no fechamento do arquivo de pontos!! ");
            exit(0);
        }

    if(opcao==1)
        if((fclose(arq_imagem))==EOF)
        {
            printf("Erro no fechamento do arquivo de imagem!! ");
            exit(0);
        }

    if(opcao==2)
        if((fclose(arq_aux))==EOF)
        {
            printf("Erro no fechamento do arquivo auxiliar!! ");

```

```

        exit(0);
    }
}

/* LE PONTO E CLASSE A QUAL PERTENCE, DE ARQUIVO .DAT, ALEM DE REA- */
/*LIZAR A CONTAGEM DE PIXELS CLASSIFICADOS CORRETAMENTE E INCORRETA-*/
/*MENTE. */
/*****
/
void le_pontos()
{
    int l,aux;

    fscanf(arq_pontos,"%d %d\n",&classe,&num_pontos);

    for(l=0;l<num_pontos;l++)
    {
        fscanf(arq_pontos,"%d %d\n",&linha,&coluna);
        aux=matriz[linha][coluna];
        vclasse[aux]++;
    }

    printf("\nAcertos: %d",vclasse[classe]);
    printf("\nErros: %d\n",num_pontos-vclasse[classe]);
    printf("\nClasse 0 (desconhecida): %d",vclasse[0]);
    printf("\nClasse 1 (nativa): %d",vclasse[1]);
    printf("\nClasse 2 (eucalyptus): %d",vclasse[2]);
    printf("\nClasse 3 (acacia): %d",vclasse[3]);
    printf("\nClasse 4 (pastagem): %d",vclasse[4]);
    printf("\nClasse 5 (solo): %d",vclasse[5]);
    printf("\nClasse 6 (agua): %d",vclasse[6]);
    printf("\n
        Total: %d",num_pontos);
}

/* PROGRAMA PRINCIPAL */
/*****
void main()
{
    abre_arq(0); /*arquivo de pontos*/
    abre_arq(1); /*imagem classificada*/
    limpa_matriz();
    le_imagem();
    le_pontos();
    fecha_arq(0);
    fecha_arq(1);
}

```

ANEXO 14. Seleção de bandas (Distância de *Bhattacharyya*)

DISTÂNCIA DE BHATTACHARYYA									
Separabilidade entre Classes									
Bandas	d12	d13	d14	d15	d16	d23	d24	d25	d26
1 2 3 4 5 7	2,629595	2,197265	2,689968	3,951919	22,739008	2,821501	9,852585	11,982310	58,250248
1 2 3 4 5	2,551048	2,177908	2,404701	3,690495	22,615526	2,787471	8,851110	10,309310	58,196110
1 3 4 5 7	2,376195	1,857107	2,566922	3,880111	22,678496	2,782418	8,204428	10,633299	57,669594
1 2 4 5 7	2,438245	2,062662	2,318950	3,614079	22,044895	2,661192	9,616177	10,093179	55,295331
1 2 3 4 7	2,464082	2,111915	2,549487	3,309010	21,981994	2,522279	9,666701	7,617517	57,931957
2 3 4 5 7	2,335977	2,174578	2,464478	3,128863	21,366252	2,626208	9,074033	9,526579	56,705708
1 3 4 5	2,280593	1,835196	2,295127	3,614544	22,564322	2,748805	7,437062	8,802948	57,607896
2 3 4 5	2,269785	2,155578	2,195197	2,957165	21,207881	2,593278	8,067980	8,771828	56,683202
1 2 4 5	2,371483	2,040141	2,022329	3,278696	21,959244	2,626205	8,607844	7,512237	55,185032
1 3 4 7	2,183666	1,766845	2,431390	3,223685	21,904528	2,476240	8,015443	6,300030	57,278246
3 4 5 7	2,075236	1,839351	2,346619	3,027612	21,313606	2,583988	7,462050	7,217334	56,169494
2 3 4 7	2,142124	2,089809	2,315773	2,771869	20,583424	2,329605	8,872563	6,868267	56,141060
2 4 5 7	2,152028	2,043165	1,974177	2,784802	20,375929	2,463455	8,754401	7,994876	52,975706
3 4 5	1,994659	1,817897	2,089974	2,854588	21,164840	2,551876	6,688457	6,507041	56,147101
1 2 4 7	2,291632	1,970917	2,206608	2,916694	21,200980	2,368576	9,434406	5,432337	54,798643
3 4 7	1,849467	1,748665	2,202788	2,670282	20,517604	2,276781	7,256236	4,994741	55,509000
2 4 5	2,093517	2,021375	1,694092	2,552530	20,267775	2,427403	7,730149	6,584107	52,925661
1 4 5 7	2,228102	1,725832	1,605505	3,443459	20,627508	2,651066	5,515477	9,749821	50,021244
2 4 7	1,979033	1,952049	1,856587	2,399230	19,467455	2,173790	8,561938	4,929874	52,011584
1 2 3 4	1,835908	2,038737	1,896200	2,370950	17,725355	2,169734	5,621113	4,773290	57,815061
1 4 5	2,136972	1,689021	1,346219	3,058260	20,568774	2,614169	4,921310	7,166071	49,848674
1 3 4	1,313177	1,657325	1,859911	2,323158	17,593768	2,084273	5,003325	3,903243	57,167003
1 2 4	1,652979	1,852683	1,401077	2,061988	17,117536	2,052369	4,987865	3,772264	54,696122
2 3 4	1,528764	2,022773	1,732205	1,936810	15,288236	2,020031	5,150244	4,083920	55,706595
1 4 7	2,045930	1,609018	1,529479	2,745396	19,802444	2,367128	5,342772	5,135772	49,583262
3 4	0,990871	1,643929	1,696904	1,880937	15,170230	1,925777	4,516033	2,772733	55,069051
2 4	1,342133	1,841434	1,149842	1,563160	14,259141	1,901118	4,364268	3,214822	51,456639
4 5 7	1,933708	1,706879	1,091346	2,418464	17,025848	2,459007	3,703152	6,155612	41,115366
4 5	1,854267	1,671217	0,854527	2,109411	16,968089	2,420541	3,139630	5,624492	41,065623
1 4	0,723495	1,163284	0,550035	1,644931	16,478477	2,023653	1,890129	3,145870	49,533442
4 7	1,717528	1,588580	1,016341	2,156894	16,093267	2,173694	3,533593	4,231838	39,499060
1 2 3 5 7	2,388072	1,246495	2,268018	2,950791	12,523193	1,071444	5,930824	10,829976	13,962924
1 3 5 7	2,130646	0,850902	2,233122	2,899461	12,367450	1,036744	5,732504	9,773135	13,880575
1 2 3 5	2,307983	1,189903	1,827400	2,744427	11,757994	0,915815	4,685535	9,383914	13,365606
4	0,366627	1,149578	0,171628	0,352799	12,028401	1,867419	0,560830	0,358371	38,459400
1 2 5 7	2,181069	1,122745	1,560195	2,640862	11,640628	0,959437	4,877739	9,025668	13,527582
2 3 5 7	2,067184	1,196042	2,125723	2,322916	12,289649	0,854560	5,461276	7,436660	13,681160
1 3 5	2,036702	0,803332	1,771606	2,692149	11,567503	0,879054	4,525915	8,160991	13,285687
3 5 7	1,796993	0,795473	2,091956	2,254496	12,145508	0,818427	5,248779	5,511823	13,600796
2 3 5	2,004430	1,125893	1,719526	2,160798	11,609930	0,719390	4,221315	6,991390	13,141167
2 5 7	1,856822	1,074125	1,338353	1,995775	11,283958	0,741765	4,192796	6,075643	13,170666
1 5 7	1,972107	0,811568	1,102982	2,491234	10,533634	0,952734	3,342045	8,728316	12,497606
1 2 5	2,116028	1,051668	0,973015	2,390898	10,739482	0,816862	3,512875	6,746105	12,901950
3 5	1,724858	0,734167	1,667958	2,092645	11,430329	0,680090	4,059613	5,069902	13,063249
2 5	1,801461	0,986856	0,799019	1,767525	10,500330	0,619970	2,818909	5,186467	12,608297
1 5	1,884920	0,773856	0,607524	2,190156	9,481757	0,814180	2,377103	6,316628	11,847260
5 7	1,639496	0,756556	0,748170	1,695294	9,384259	0,739678	2,056835	4,533727	11,173405
1 2 3 7	2,181819	0,966737	1,793536	2,634626	7,659028	0,953921	4,747298	7,126087	7,021020
2 3 7	1,792622	0,892841	1,685632	2,192241	7,541736	0,740238	4,259259	5,863521	6,262800
5	1,570071	0,706703	0,323057	1,269510	8,539021	0,617670	1,177265	4,138090	10,666228
1 3 7	1,884242	0,509135	1,704830	2,578620	7,262813	0,919158	4,565274	5,976404	6,876534
3 7	1,467530	0,416699	1,605268	2,123965	7,161750	0,701262	4,081637	4,155496	6,122359
1 2 7	1,989481	0,846220	0,940943	2,286822	6,298773	0,845458	3,563136	5,014804	6,500482
2 7	1,600581	0,774163	0,760474	1,835109	6,072213	0,631000	2,830832	4,138251	5,546804
1 7	1,737868	0,448295	0,663114	2,135045	5,314832	0,843729	2,583294	4,709707	5,767671
1 2 3	1,542660	0,895298	1,461464	1,876411	2,692378	0,306268	4,010276	4,552157	4,607333
7	1,325352	0,354532	0,381307	1,586108	4,477377	0,630907	1,382534	3,392298	3,611087
1 3	0,982344	0,371964	1,383205	1,849318	2,106766	0,225140	3,817961	3,735460	4,470156
2 3	1,161712	0,830754	1,354968	1,520564	2,220994	0,154716	3,551074	3,572731	2,804846
1 2	1,367101	0,764719	0,682609	1,559493	1,538788	0,222414	2,852105	3,530157	4,153693
3	0,560846	0,288878	1,283260	1,488237	1,674646	0,064826	3,356769	2,310394	2,670974
2	0,988606	0,703595	0,509524	1,125994	0,834349	0,073494	2,160215	2,709591	2,054711
1	0,435176	0,080475	0,299198	1,219604	1,192086	0,156693	1,274573	2,973555	3,589388

DISTÂNCIA DE BHATTACHARYYA
Separabilidade entre Classes

d34	d35	d36	d45	d46	d56	dmédio
4,879936	7,689060	36,547916	1,580242	5,538541	21,228668	12,971917
4,472025	6,751751	35,905051	1,422760	5,376473	20,623906	12,542376
4,470958	6,574199	36,208037	1,480167	5,139720	21,023642	12,503020
4,503415	6,567815	35,010840	1,367864	5,334076	20,005740	12,195617
4,630659	5,321933	35,953365	1,398274	5,260845	18,827144	12,102478
4,606659	6,194662	36,368186	1,376029	5,279901	18,202518	12,095375
4,100122	5,564697	35,623877	1,317517	4,949090	20,284327	12,068408
4,206497	5,723012	35,703920	1,251233	5,121565	17,845876	11,783600
4,071349	5,105091	34,580864	1,138206	5,163049	18,824979	11,632450
4,208861	4,295192	35,527528	1,299014	4,854557	18,521669	11,619128
4,212209	4,511926	36,050052	1,282552	4,903614	17,891001	11,525776
4,342527	4,713608	35,651213	1,255409	5,042803	17,289798	11,493990
4,142821	5,183213	34,742701	1,173553	5,102776	17,479993	11,289573
3,847986	4,060315	35,443766	1,155528	4,718445	17,524297	11,237785
4,276912	4,014889	34,139561	1,179844	5,056356	17,252366	11,236048
3,933663	3,300324	35,249009	1,168035	4,667880	16,938448	10,952195
3,716078	4,339750	34,298142	0,963865	4,937052	17,014405	10,904393
2,351251	6,051943	30,269288	1,234999	4,212761	17,336055	10,601621
3,905612	3,516049	33,651379	1,042903	4,879320	16,247990	10,571653
3,734416	3,828413	31,680028	1,085567	4,716658	14,363122	10,376970
2,019947	4,697568	30,062567	0,949380	4,024188	15,966707	10,071322
3,484918	3,085687	31,278231	0,968675	4,417655	13,999721	10,009328
3,030369	3,117848	30,122659	0,682571	4,565296	14,141025	9,683643
3,541864	3,297877	30,318155	0,957557	4,594608	12,982991	9,677509
2,149631	3,634011	29,315133	1,022151	3,941987	14,646617	9,658049
3,289276	2,234566	29,960849	0,861899	4,295959	12,706109	9,267675
2,767687	2,641459	28,424597	0,534246	4,460358	12,778633	8,846636
1,584650	3,558481	27,816059	1,001410	3,551024	16,616137	8,782476
1,268616	3,260386	27,634684	0,707469	3,368392	15,743127	8,512698
1,128445	2,383044	26,297504	0,474687	3,517101	12,374156	8,221884
1,370658	2,669171	25,904949	0,865336	3,370426	14,483117	8,044963
4,364653	7,518709	17,184863	1,346931	3,443551	14,801760	6,788814
4,082687	6,457202	17,002203	1,178143	3,405489	14,343776	6,491603
3,853357	6,648078	16,695875	1,141028	3,298189	12,868382	6,178899
0,519615	0,248050	20,764192	0,198296	3,019720	12,216581	6,152101
3,456983	6,431318	16,691963	1,041501	3,164386	13,547503	6,124636
4,155862	5,930230	17,118827	1,174981	3,335296	12,323764	6,098275
3,577562	5,459399	16,493899	0,882466	3,258508	11,686264	5,805402
3,869831	4,348098	16,938154	1,021275	3,297451	11,689273	5,695222
3,661518	5,561832	16,604220	1,008153	3,195512	11,480890	5,680398
3,162519	4,973450	16,658074	0,864309	3,059349	11,551038	5,466576
1,991725	5,939941	14,910464	0,943617	2,720779	12,499868	5,429241
2,774047	5,007720	16,130985	0,547681	3,011476	10,247111	5,264527
3,389074	3,958727	16,399824	0,774731	3,155600	10,394070	5,239656
2,495868	4,248225	16,079430	0,347645	2,909982	9,730336	4,860021
1,550275	4,614677	14,293139	0,452826	2,577047	9,255413	4,602451
1,312417	3,422311	14,671962	0,757715	2,490172	11,438984	4,454732
3,720083	5,138105	8,265808	1,075705	3,191066	7,707745	4,278839
3,515284	4,597476	8,180457	0,968218	3,090826	7,516704	3,939990
0,927836	3,157118	14,102111	0,227614	2,349452	9,194582	3,931089
3,426328	4,035375	7,870550	0,809647	3,110837	6,580376	3,874008
3,228972	3,168633	7,799339	0,728709	3,011993	6,391727	3,477689
2,613379	3,785503	7,422869	0,556099	2,813196	5,697024	3,411613
2,311559	3,385751	7,283489	0,375221	2,713575	5,611059	3,058005
1,518557	3,401405	6,145796	0,495026	2,463770	5,211144	2,895950
3,239276	3,513914	3,551084	0,885021	1,079584	0,245017	2,297209
0,885541	2,546632	5,332024	0,332185	2,249756	4,888937	2,225105
2,931942	2,682130	3,178979	0,679884	0,614886	0,051930	1,938804
3,051243	3,124225	2,695904	0,797063	1,001899	0,196585	1,869285
2,153516	2,806675	2,891722	0,354153	0,273098	0,079088	1,681955
2,746531	2,029611	2,358061	0,614127	0,544708	0,020171	1,467469
1,870987	2,468776	1,874978	0,197731	0,139235	0,008938	1,181381
0,651533	1,920597	2,080367	0,256464	0,178828	0,046055	1,090308

ANEXO 15. Acertos e erros obtidos pelo método de Máxima Verossimilhança Gaussiana e pela Rede Neural Multinível com *BackPropagation*

TABELA AIII - Acertos obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de treinamento (em *pixels*)

	Total de Pontos	MAXVER1	MAXVER2	MAXVER3	MAXVER4	MAXVER5	MAXVER6
Nativa	212	191	164	182	179	176	188
<i>Eucalyptus</i>	219	210	210	209	212	210	212
<i>Acácia</i>	212	203	198	198	196	201	205
Pastagem	212	184	125	171	181	103	194
Solo	69	63	40	45	45	42	57
Água	129	118	116	106	105	114	117

TABELA AIV - Distribuição de erros obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de treinamento (em *pixels*)

MAXVER1	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	21	2	-----	0	16	3	0	0
<i>Eucalyptus</i>	9	1	4	-----	4	0	0	0
<i>Acácia</i>	9	4	5	0	-----	0	0	0
Pastagem	28	11	3	0	0	-----	14	0
Solo	6	4	0	0	0	2	-----	0
Água	11	11	0	0	0	0	0	-----
MAXVER2	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	48	9	-----	1	16	22	0	0
<i>Eucalyptus</i>	9	5	0	-----	4	0	0	0
<i>Acácia</i>	14	9	5	0	-----	0	0	0
Pastagem	87	68	1	0	0	-----	18	0
Solo	29	18	0	0	0	11	-----	0
Água	13	13	0	0	0	0	0	-----
MAXVER3	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	30	2	-----	1	16	11	0	0
<i>Eucalyptus</i>	10	1	0	-----	9	0	0	0
<i>Acácia</i>	14	3	11	0	-----	0	0	0
Pastagem	41	35	5	0	0	-----	1	0
Solo	24	12	0	0	0	12	-----	0
Água	23	23	0	0	0	0	0	-----
MAXVER4	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	33	8	-----	0	15	10	0	0
<i>Eucalyptus</i>	7	1	2	-----	4	0	0	0
<i>Acácia</i>	16	7	9	0	-----	0	0	0
Pastagem	31	23	4	0	0	-----	4	0
Solo	24	14	0	0	0	10	-----	0
Água	24	22	0	0	0	2	0	-----
MAXVER5	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	36	6	-----	1	15	14	0	0
<i>Eucalyptus</i>	9	5	0	-----	4	0	0	0
<i>Acácia</i>	11	6	4	1	-----	0	0	0
Pastagem	109	69	2	0	0	-----	38	0
Solo	27	20	0	0	0	7	-----	0
Água	15	15	0	0	0	0	0	-----
MAXVER6	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	24	3	-----	4	14	3	0	0
<i>Eucalyptus</i>	7	1	2	-----	4	0	0	0
<i>Acácia</i>	7	2	5	0	-----	0	0	0
Pastagem	18	12	2	0	0	-----	4	0
Solo	12	6	0	0	0	6	-----	0
Água	12	12	0	0	0	0	0	-----

TABELA AV - Acertos obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de reconhecimento (em *pixels*)

	Total de Pontos	MAXVER1	MAXVER2	MAXVER3	MAXVER4	MAXVER5	MAXVER6
Nativa	60	34	30	31	35	28	40
<i>Eucalyptus</i>	60	18	18	21	19	17	19
<i>Acácia</i>	60	29	30	31	28	29	34
Pastagem	60	40	33	39	38	24	40
Solo	60	26	28	20	23	39	26
Água	60	28	26	12	15	21	27

TABELA AVI - Distribuição de erros obtidos pelo método de Máxima Verossimilhança Gaussiana para o conjunto de reconhecimento (em *pixels*)

MAXVER1	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	26	9	-----	3	9	5	0	0
<i>Eucalyptus</i>	42	8	28	-----	5	1	0	0
<i>Acácia</i>	31	2	23	1	-----	3	2	0
Pastagem	20	3	13	0	0	-----	4	0
Solo	34	16	0	0	0	18	-----	0
Água	32	24	0	0	0	7	1	-----
MAXVER2	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	30	12	-----	2	8	8	0	0
<i>Eucalyptus</i>	42	17	19	-----	5	1	0	0
<i>Acácia</i>	30	8	15	3	-----	4	0	0
Pastagem	27	16	6	0	1	-----	4	0
Solo	32	12	0	0	0	14	-----	0
Água	34	34	0	0	0	0	0	-----
MAXVER3	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	29	11	-----	3	8	7	0	0
<i>Eucalyptus</i>	39	8	25	-----	5	1	0	0
<i>Acácia</i>	29	7	18	3	-----	1	0	0
Pastagem	21	9	10	0	0	-----	2	0
Solo	40	16	0	0	0	24	-----	0
Água	48	44	0	0	0	3	1	-----
MAXVER4	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	25	10	-----	3	6	6	0	0
<i>Eucalyptus</i>	41	8	29	-----	4	0	0	0
<i>Acácia</i>	32	8	18	4	-----	2	0	0
Pastagem	22	5	13	0	1	-----	3	0
Solo	37	16	0	0	0	21	-----	0
Água	45	40	0	0	0	5	0	-----
MAXVER5	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	32	12	-----	3	9	8	0	0
<i>Eucalyptus</i>	43	17	18	-----	7	1	0	0
<i>Acácia</i>	31	9	15	4	-----	2	1	0
Pastagem	36	22	6	0	0	-----	8	0
Solo	21	18	0	0	0	3	-----	0
Água	39	39	0	0	0	0	0	-----
MAXVER6	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	20	2	-----	4	8	6	0	0
<i>Eucalyptus</i>	41	3	31	-----	7	0	0	0
<i>Acácia</i>	26	2	18	4	-----	2	0	0
Pastagem	20	2	12	0	1	-----	5	0
Solo	34	11	0	0	0	23	-----	0
Água	33	25	0	0	0	8	0	-----

TABELA AVII - Acertos obtidos pela Rede Neural Multinível com *BackPropagation* para o conjunto de treinamento (em *pixels*)

	Total de Pontos	RNA1	RNA2	RNA3	RNA4	RNA5	RNA6
Nativa	212	197	188	198	178	194	196
<i>Eucalyptus</i>	219	216	213	212	210	213	214
<i>Acácia</i>	212	210	208	209	211	209	210
Pastagem	212	210	208	209	196	205	204
Solo	69	69	69	69	67	69	68
Água	129	129	129	129	129	129	129

TABELA AVIII - Distribuição de erros obtidos pela Rede Neural Multinível com *BackPropagation* para o conjunto de treinamento (em *pixels*)

RNA1	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	15	7	-----	0	4	4	0	0
<i>Eucalyptus</i>	3	1	1	-----	1	0	0	0
<i>Acácia</i>	2	1	1	0	-----	0	0	0
Pastagem	2	0	0	0	0	-----	2	0
Solo	0	0	0	0	0	0	-----	0
Água	0	0	0	0	0	0	0	-----
RNA2	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	24	8	-----	2	4	10	0	0
<i>Eucalyptus</i>	6	4	1	-----	1	0	0	0
<i>Acácia</i>	4	3	1	0	-----	0	0	0
Pastagem	4	0	0	0	0	-----	4	0
Solo	0	0	0	0	0	0	-----	0
Água	0	0	0	0	0	0	0	-----
RNA3	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	14	2	-----	2	5	5	0	0
<i>Eucalyptus</i>	7	1	5	-----	1	0	0	0
<i>Acácia</i>	3	1	2	0	-----	0	0	0
Pastagem	3	0	1	0	0	-----	2	0
Solo	0	0	0	0	0	0	-----	0
Água	0	0	0	0	0	0	0	-----
RNA4	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	34	15	-----	4	5	10	0	0
<i>Eucalyptus</i>	9	4	5	-----	0	0	0	0
<i>Acácia</i>	1	0	1	0	-----	0	0	0
Pastagem	16	9	1	0	0	-----	5	1
Solo	2	1	0	0	0	1	-----	0
Água	0	0	0	0	0	0	0	-----
RNA5	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	18	7	-----	2	5	4	0	0
<i>Eucalyptus</i>	6	1	2	-----	3	0	0	0
<i>Acácia</i>	3	2	1	0	-----	0	0	0
Pastagem	7	3	1	0	0	-----	3	0
Solo	0	0	0	0	0	0	-----	0
Água	0	0	0	0	0	0	0	-----
RNA6	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	16	10	-----	0	4	2	0	0
<i>Eucalyptus</i>	5	5	0	-----	0	0	0	0
<i>Acácia</i>	2	1	1	0	-----	0	0	0
Pastagem	8	6	1	0	0	-----	1	0
Solo	1	1	0	0	0	0	-----	0
Água	0	0	0	0	0	0	0	-----

TABELA AIX - Acertos obtidos pela Rede Neural Multinível com *BackPropagation* para o conjunto de reconhecimento (em *pixels*)

	Total de Pontos	RNA1	RNA2	RNA3	RNA4	RNA5	RNA6
Nativa	60	34	31	38	36	32	37
<i>Eucalyptus</i>	60	23	26	22	18	21	19
<i>Acácia</i>	60	32	33	32	34	32	33
Pastagem	60	40	41	39	37	38	33
Solo	60	41	44	38	44	42	37
Água	60	28	34	43	39	32	47

TABELA AX - Distribuição de erros obtidos pela Rede Neural Multinível com *BackPropagation* para o conjunto de reconhecimento (em *pixels*)

RNA1	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	26	3	-----	6	10	5	2	0
<i>Eucalyptus</i>	37	5	22	-----	10	0	0	0
<i>Acácia</i>	28	6	14	5	-----	3	0	0
Pastagem	20	0	12	0	1	-----	7	0
Solo	19	0	0	0	0	19	-----	0
Água	32	20	0	0	0	9	3	-----
RNA2	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	29	11	-----	2	8	6	2	0
<i>Eucalyptus</i>	34	6	18	-----	9	1	0	0
<i>Acácia</i>	27	8	11	6	-----	2	0	0
Pastagem	19	3	10	0	1	-----	5	0
Solo	16	0	0	0	0	16	-----	0
Água	26	4	0	0	0	21	1	-----
RNA3	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	22	1	-----	2	10	6	3	0
<i>Eucalyptus</i>	38	1	25	-----	10	2	0	0
<i>Acácia</i>	28	4	23	1	-----	0	0	0
Pastagem	21	1	13	0	1	-----	6	0
Solo	22	0	0	0	0	22	-----	0
Água	17	1	0	0	0	15	1	-----
RNA4	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	24	4	-----	3	9	5	2	1
<i>Eucalyptus</i>	42	7	27	-----	6	2	0	0
<i>Acácia</i>	26	5	16	1	-----	4	0	0
Pastagem	23	3	13	1	1	-----	4	1
Solo	16	1	1	0	0	14	-----	0
Água	21	3	1	0	0	17	0	-----
RNA5	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	28	4	-----	5	11	6	2	0
<i>Eucalyptus</i>	39	5	25	-----	7	2	0	0
<i>Acácia</i>	28	6	12	6	-----	4	0	0
Pastagem	22	4	12	0	0	-----	6	0
Solo	18	1	0	0	0	17	-----	0
Água	28	2	0	0	0	6	20	-----
RNA6	Total de erros	0 Desconh	1 Nativa	2 <i>Eucalypt</i>	3 <i>Acácia</i>	4 Pastagem	5 Solo	6 Água
Nativa	23	6	-----	3	7	5	2	0
<i>Eucalyptus</i>	41	10	23	-----	8	0	0	0
<i>Acácia</i>	27	8	13	4	-----	2	0	0
Pastagem	27	4	15	0	1	-----	6	3
Solo	23	5	0	0	0	18	-----	0
Água	13	4	0	0	0	9	0	-----