

MINISTÉRIO DA EDUCAÇÃO

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

Dissertação de Mestrado

**CLASSIFICAÇÃO HIERÁRQUICA ORIENTADA A OBJETO EM
IMAGENS DE ALTA RESOLUÇÃO ESPACIAL EMPREGANDO
ATRIBUTOS ESPACIAIS E ESPECTRAIS**

Por

Marlos Henrique Batista

Orientador

Prof. Vitor Haertel Ph.D.

Porto Alegre, maio de 2006

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

**CLASSIFICAÇÃO HIERÁRQUICA ORIENTADA A OBJETO EM
IMAGENS DE ALTA RESOLUÇÃO ESPACIAL EMPREGANDO
ATRIBUTOS ESPACIAIS E ESPECTRAIS**

Por

Marlos Henrique Batista

Engenheiro Cartógrafo (2002 – UFPR)

Mestrando em Sensoriamento Remoto (PPGSR – CEPSRM/UFRGS)

Orientação

Prof. Vitor Haertel Ph.D.

*Dissertação submetida ao Programa de Pós-Graduação
em Sensoriamento Remoto do Centro Estadual de
Pesquisas em Sensoriamento Remoto e Meteorologia –
UFRGS, como requisito parcial para obtenção do grau de
Mestre em Sensoriamento Remoto*

Linha de Pesquisa: Reconhecimento de Padrões

Orientador: Prof. Dr. Vitor Haertel

Banca Examinadora:

Prof. Dr. Jorge Centeno

Prof^a. Dr^a. Patrícia Zielgelmann

Prof. Dr. Philippe Olivier Alexandre Navaux

Porto Alegre, maio de 2006

*“Se consegui enxergar
mais longe
é porque estava apoiado
sobre ombros de gigantes.”*

Isaac Newton

AGRADECIMENTOS

Na vida, nada se constrói sozinho. Os próprios elementos da natureza constituem todas as coisas se combinados entre si. Agradeço, assim, através de metáforas,

À minha “gigante” família, que, representando o elemento “terra”, proporcionou-me toda a estrutura e segurança para que eu persistisse naquilo em que almejava. Ao meu pai, um homem exemplar que conseguiu construir uma família unida pelo respeito e pelo amor. Minha mãe, por suas orações e incentivos. Meus irmãos, que sempre torceram pelo meu êxito acadêmico e profissional.

Aos meus “gigantes” amigos, simbolizando o “fogo”: vocês trouxeram, no decorrer dessa jornada, entusiasmo, luz, energia e vontade de seguir adiante.

Aos “gigantes” mestres, especialmente ao professor Vitor Haertel, que, com tamanha presteza, dedicou seu tempo para confiar em minha capacidade. Denotando o “ar” – responsável pela manutenção da vida acadêmica –, vocês contribuíram efetivamente para o meu enriquecimento pessoal e intelectual.

À minha “gigante” amada Sabrina Camejo, por sua colaboração tão indispensável quanto diversificada. Fonte de inspiração que sempre esteve comigo nos momentos mais difíceis dessa caminhada. A “água”, essencial à vida.

Ao “gigante” Deus, que sempre esteve presente, fazendo da derrota uma vitória, da fraqueza, uma grande força. Completando o ciclo de elementos, retratando o “éter” – ou quinta essência – a fonte dos outros quatro. Na validade dessa luta, nos méritos dessa conquistas há muito da Sua presença.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro recebido, sem o qual não seria possível a realização deste curso.

À Universidade Federal do Rio Grande do Sul (UFRGS) e a todos que, de alguma maneira, contribuíram com o desenvolvimento desta dissertação.

SUMÁRIO

LISTA DE TABELAS	vi
LISTA DE FIGURAS	viii
LISTA DE ANEXOS	xiii
LISTA DE ABREVIATURAS	xiv
RESUMO	xv
ABSTRACT	xvi
1. INTRODUÇÃO.....	01
2. REVISÃO BIBLIOGRÁFICA.....	06
2.1. EVOLUÇÃO DOS DADOS DE SENSORES REMOTOS	06
2.2. ATRIBUTOS ESPACIAIS: PRERROGATIVAS	08
2.3. RESOLUÇÃO ESPACIAL X RESOLUÇÃO ESPECTRAL.....	11
2.4. SOLUÇÕES PROPOSTAS	17
2.5. MÉTODOS DE CLASSIFICAÇÃO	23
2.5.1. Classificador de Máxima Verossimilhança.....	24
2.5.2. Classificador Discriminante Linear de Fisher	26
2.5.3. Classificador da Distância Mínima Euclidiana	26
2.5.4. Comparação entre os Classificadores	26
2.6. CLASSIFICADORES DE DECISÃO EM ÁRVORE	27
2.7. MODELOS DE CLASSIFICADORES DE DECISÃO EM ÁRVORE	31
3. METODOLOGIA.....	32
3.1. SEGMENTAÇÃO.....	32
3.1.1. Métodos de Segmentação	33
3.1.2. Segmentação Baseada em Objetos (Multiresolução)	39

3.2. ATRIBUTOS PARA CARACTERIZAÇÃO DOS OBJETOS	46
3.2.1. Atributos Espectrais.....	50
3.2.2. Atributos Espaciais	54
3.3. UTILIZAÇÃO CONJUNTA DE ATR SPECTRAIS E ESPACIAIS NO PROCESSO DE CLASSIFICAÇÃO.....	74
3.3.1. Seleção de Feições e Separabilidade Estatística.....	74
3.3.2. Seqüencial Foward Selection (SFS)	78
4. EXPERIMENTO	81
4.1. MATERIAIS	83
4.2. ÁREA DE ESTUDO	83
4.3. CARACTERÍSTICAS DOS DADOS IMAGEM	84
4.4. EXPERIMENTOS DE SEGMENTAÇÃO	86
4.5. ATRIBUTOS ESPECTRAIS E ESPACIAIS	91
4.6. AMOSTRAS DE TREINAMENTO E DE TESTES	93
4.7. SELEÇÃO PRELIMINAR DAS VARIÁVEIS E CLASSES DE INFORMAÇÃO	94
4.8. EXPERIMENTOS DO CDA	101
4.8.1. Construção da Árvore de Decisão	101
4.8.2. Classificação com a Árvore de Decisão	105
4.8.3. Experimento com Limiar de Verossimilhança de 80%	107
4.8.4. Experimento com Limiar de Verossimilhança de 90%	118
4.8.5. Experimento com Limiar de Verossimilhança de 95%	128
4.8.6. Experimento com Limiar de Verossimilhança de 99%	139
4.8.7. CDA x CEU.....	149
4.8.8. Acurácias (Análise Comparativa).....	154
5. CONCLUSÃO.....	157
REFERÊNCIAS BIBLIOGRÁFICAS	162
ANEXOS	166

LISTA DE TABELAS

Tabela 1 – Ponderações ao critério de homogeneidade conforme níveis de segmentação do primeiro conjunto de experimentos	87
Tabela 2 – Estatísticas do resultado de segmentação do primeiro conjunto de experimentos	89
Tabela 3 – Ponderações ao critério de homogeneidade conforme níveis de segmentação do segundo conjunto de experimentos.....	89
Tabela 4 – Estatísticas do resultado de segmentação do segundo conjunto de experimentos.....	90
Tabela 5 - Estrutura da matriz de objetos e variáveis.....	92
Tabela 6 – Status da seleção das variáveis espectrais e espaciais.....	94
Tabela 7 – Quantidade de amostras de treinamento e de testes por classes de informação.....	96
Tabela 8 – Tabela de Contingência do CDA 1.....	109
Tabela 9 – Tabela de Contingência do CDA 2.....	111
Tabela 10 – Tabela de Contingência do CDA 3.....	113
Tabela 11 – Tabela de Contingência do CDA 4.....	115
Tabela 12 – Tabela de Contingência do CDA 5.....	120
Tabela 13 – Tabela de Contingência do CDA 6.....	122
Tabela 14 – Tabela de Contingência do CDA 7.....	124
Tabela 15 – Tabela de Contingência do CDA 8.....	126
Tabela 16 – Tabela de Contingência do CDA 9.....	130
Tabela 17 – Tabela de Contingência do CDA 10.....	132
Tabela 18 – Tabela de Contingência do CDA 11.....	134
Tabela 19 – Tabela de Contingência do CDA 12.....	136
Tabela 20 – Tabela de Contingência do CDA 13.....	141

Tabela 21 – Tabela de Contingência do CDA 14.....	143
Tabela 22 – Tabela de Contingência do CDA 15.....	145
Tabela 23 – Tabela de Contingência do CDA 16.....	147
Tabela 24 – Tabela de Contingência do CEU	154

LISTA DE FIGURAS

Figura 1 – Fotoidentificação dos Atributos Espaciais e Espectrais das Classes de Informação.....	09
Figura 2 – Confrontação espectral e espacial entre dados imagem dos sistemas <i>Landsat</i> e <i>Quickbird</i>	13
Figura 3 – Exemplo de histograma da classe de informação área urbana de dados imagem do sistema <i>Landsat</i>	17
Figura 4 – Histograma de classes de informação de dados imagem do sistema <i>Quickbird</i> (padrão: <i>pixel</i>)	18
Figura 5 – Histograma combinado de classes de informação dos dados imagem do sistema <i>Quickbird</i> (padrão: <i>pixel</i>)	21
Figura 6 – Objetos criados por segmentação em dados imagem de alta resolução espacial	22
Figura 7 – Estrutura geral de um classificador de decisão em árvore	28
Figura 8 – Exemplo de segmentação pelo método de limiarização com uma imagem sintética.....	35
Figura 9 – Exemplo de under-segmentation sobre dados imagem do sistema <i>Quickbird</i>	37
Figura 10 – Exemplo de over-segmentation sobre dados imagem do sistema <i>Quickbird</i>	38
Figura 11 – Exemplo de dados imagem do sistema <i>Quickbird</i> com representação do ambiente urbano	48
Figura 12 – Representação do atributo espectral da variável brilho sobre os dados imagem apresentados pela Figura 12	48
Figura 13 – Representação do atributo espacial (geometria) da variável área sobre os dados imagem apresentados pela Figura 12.....	49
Figura 14 – Representação do atributo espacial (textura) da variável homogeneidade sobre os dados imagem apresentados pela Figura 12.....	49
Figura 15 – Parâmetros qualitativos dos objetos para formação da variável espacial comprimento	57

Figura 16 – Orientação aos relacionamentos angulares da GLCM	66
Figura 17 – Representação sintética dos contadores digitais de uma imagem digital	67
Figura 18 – Representação da matriz de coocorrência dos contadores digitais na direção horizontal (0°) da Figura 19	68
Figura 19 – Referência quanto à localização espacial dos dados imagem Quickbird da área de estudo	84
Figura 20 – Níveis de segmentação do primeiro conjunto de experimentos	88
Figura 21 – Exemplo de identificação de objetos em cada variável espectral, espacial (geometria) e espacial (textura), respectivamente	93
Figura 22 – Assinatura espectral/espacial para a classe Edificação – Telhado Claro	97
Figura 23 – Assinatura espectral/espacial para a classe Edificação – Telhado Escuro ...	97
Figura 24 – Assinatura espectral/espacial para a classe Edificação – Telhado Cerâmica.....	98
Figura 25 – Assinatura espectral/espacial para a classe Vegetação Arbórea.....	98
Figura 26– Assinatura espectral/espacial para a classe Vegetação Rasteira.....	99
Figura 27 – Assinatura espectral/espacial para a classe Solo Exposto	99
Figura 28 – Assinatura espectral/espacial para a classe Vias	100
Figura 29 – Assinaturas espectral/espacial para as sete classes de informação.....	100
Figura 30 – Estrutura inicial do CDA em estrutura binária pelo método bottom-up (exemplo sintético)	103
Figura 31 – CDA em estrutura binária com as variáveis selecionadas pelo SFS no nó raiz (exemplo sintético)	104
Figura 32 – CDA em estrutura binária com apresentação das classes em nós descendentes (exemplo sintético).....	105
Figura 33 – Árvore final de um CDA em estrutura binária (exemplo sintético).....	105
Figura 34 – Árvore de decisão em estrutura binária (exemplo sintético).....	106
Figura 35 – CDA 1: LV de 80% e 5 feições em cada nó.....	108
Figura 36 – Variáveis definidas via SFS do CDA 1 com 5 feições em cada nó.....	108

Figura 37 – CDA 2: LV de 80% e 10 feições em cada nó.....	110
Figura 38 – Variáveis definidas via SFS do CDA 2 com 10 feições em cada nó.....	110
Figura 39 – CDA 3: LV de 80% e 15 feições em cada nó.....	112
Figura 40 – Variáveis definidas via SFS do CDA 3 com 15 feições em cada nó.....	112
Figura 41 – CDA 4: LV de 80% e 20 feições em cada nó.....	114
Figura 42 – Variáveis definidas via SFS do CDA 4 com 20 feições em cada nó.....	114
Figura 43 – Gráfico de acurácias do primeiro conjunto de experimentos do CDA.....	116
Figura 44 – Gráfico de acurácias do usuário para o primeiro conjunto de experimentos do CDA	117
Figura 45 – Gráfico de acurácias do produtor para o primeiro conjunto de experimentos do CDA	117
Figura 46 – CDA 5: LV de 90% e 5 feições em cada nó.....	118
Figura 47 – Variáveis definidas via SFS do CDA 5 com 5 feições em cada nó.....	119
Figura 48 – CDA 6: LV de 90% e 10 feições em cada nó.....	120
Figura 49 – Variáveis definidas via SFS do CDA 6 com 10 feições em cada nó.....	121
Figura 50 – CDA 7: LV de 90% e 15 feições em cada nó.....	122
Figura 51 – Variáveis definidas via SFS do CDA 7 com 15 feições em cada nó.....	123
Figura 52 – CDA 8: LV de 90% e 20 feições em cada nó.....	124
Figura 53 – Variáveis definidas via SFS do CDA 8 com 20 feições em cada nó.....	125
Figura 54 – Gráfico de acurácias do segundo conjunto de experimentos do CDA	127
Figura 55 – Gráfico de acurácias do usuário para o segundo conjunto de experimentos do CDA	127
Figura 56 – Gráfico de acurácias do produtor para o segundo conjunto de experimentos do CDA	128
Figura 57 – CDA 9: LV de 95% e 5 feições em cada nó.....	129
Figura 58 – Variáveis definidas via SFS do CDA 9 com 5 feições em cada nó.....	129
Figura 59 – CDA 10: LV de 95% e 10 feições em cada nó.....	131

Figura 60 – Variáveis definidas via SFS do CDA 10 com 10 feições em cada nó.....	131
Figura 61 – CDA 11: LV de 95% e 15 feições em cada nó.....	133
Figura 62 – Variáveis definidas via SFS do CDA 11 com 15 feições em cada nó.....	133
Figura 63 – CDA 12: LV de 95% e 20 feições em cada nó.....	135
Figura 64 – Variáveis definidas via SFS do CDA 12 com 20 feições em cada nó.....	135
Figura 65 – Gráfico de acurácias do terceiro conjunto de experimentos do CDA	137
Figura 66 – Gráfico de acurácias do usuário para o terceiro conjunto de experimentos do CDA	138
Figura 67 – Gráfico de acurácias do produtor para o terceiro conjunto de experimentos do CDA	138
Figura 68 – CDA 13: LV de 99% e 5 feições em cada nó.....	139
Figura 69 – Variáveis definidas via SFS do CDA 13 com 5 feições em cada nó.....	140
Figura 70 – CDA14: LV de 99% e 10 feições em cada nó.....	141
Figura 71 – Variáveis definidas via SFS do CDA 14 com 10 feições em cada nó.....	142
Figura 72 – CDA 15: LV de 99% e 15 feições em cada nó.....	143
Figura 73 – Variáveis definidas via SFS do CDA 15 com 15 feições em cada nó.....	144
Figura 74 – CDA 16: LV de 99% e 20 feições em cada nó.....	145
Figura 75 – Variáveis definidas via SFS do CDA 16 com 20 feições em cada nó.....	146
Figura 76 – Gráfico de acurácias do quarto conjunto de experimentos do CDA	148
Figura 77 – Gráfico de acurácias do usuário para o quarto conjunto de experimentos do CDA	148
Figura 78 – Gráfico de acurácias do produtor para o quarto conjunto de experimentos do CDA	149
Figura 79 – Resultado gráfico do CEU e do CDA.....	150
Figura 80 – Resultado gráfico do CEU e do CDA para a Área 1	151
Figura 81 – Resultado gráfico do CEU e do CDA para a Área 2	152
Figura 82 – Resultado gráfico do CEU e do CDA para a Área 3	153

Figura 83 – Gráfico de avaliação da acurácia pelo índice <i>Kappa</i> entre todos os experimentos do CDA e o CEU	155
Figura 84 – Gráfico de avaliação da acurácia média do usuário entre todos os experimentos do CDA e o CEU	156
Figura 85 – Gráfico de avaliação da acurácia média do classificador entre todos os experimentos do CDA e o CEU	156
Figura 86 – Gráfico de avaliação da utilização conjunta dos atributos espectrais e espaciais entre todos os experimentos do CDA	158

LISTA DE ANEXOS

Anexo 1 – Características técnicas do sistema <i>Quickbird</i>	166
Anexo 2 – Dados imagem do sistema <i>Quickbird</i> no formato multiespectral.....	168
Anexo 3 – Dados imagem do sistema <i>Quickbird</i> no formato pancromático.....	170
Anexo 4 – Dados imagem do sistema <i>Quickbird</i> no formato híbrido.....	172
Anexo 5 – Histogramas dos dados imagem do sistema <i>Quickbird</i>	174
Anexo 6 – Dedução analítica da normalização dos dados na classificação por Máxima Verossimilhança <i>Gaussiana</i>	178
Anexo 7 – Algoritmos em <i>Matlab</i>	182

LISTA DE ABREVIATURAS

ASTER	<i>Advanced Spaceborne Thermal Emission and Reflection Radiometer;</i>
CART	<i>Classification and Regression Trees;</i>
CBERS	<i>China-Brazil Earth Resources Satellite;</i>
CD	Contador digital;
CDA	Classificador de Decisão em Árvore;
CEU	Classificador em Estágio Único;
CEM	Classificador em Estágio Múltiplo;
ERTS	<i>Earth Resources Technology Satellite;</i>
GIS	<i>Geographic Information System;</i>
GLCM	<i>Grey Level Cooccurrence Matrix;</i>
IFOV	<i>Instantaneous field of view;</i>
LANDSAT	<i>Land Remote Sensing Satellite;</i>
LV	Limiar de verossimilhança;
MVG	Máxima Verossimilhança Gaussiana;
PCA	Análise de Componentes Principais
SBFS	<i>Algoritmo Sequential Backward Floating Selection;</i>
SBS	<i>Algoritmo Sequential Backward Selection;</i>
SFFS	<i>Algoritmo Sequential Forward Floating Selection;</i>
SFS	<i>Algoritmo Sequential Forward Selection;</i>
SPOT	<i>Systeme pour l'Observation de la Terre;</i>

CLASSIFICAÇÃO HIERÁRQUICA ORIENTADA A OBJETO EM IMAGENS DE ALTA RESOLUÇÃO ESPACIAL EMPREGANDO ATRIBUTOS ESPACIAIS E ESPECTRAIS ¹

Autor: **Marlos Henrique Batista**
Orientador: **Prof. Vitor Haertel Ph.D.**

A alta resolução espacial, incorporada aos novos sensores remotos imageadores, apresenta um cenário que promove uma captura excessiva das variações espectrais das classes, funcionando mais como ruído e aumentando desnecessariamente a variância interna das classes. Estas características geram prejuízos no processo de classificação, pois aumentam o erro de *Bayes* e conseqüentemente pioram a acurácia da classificação. Por isso, a necessidade de abandonar o *pixel* como unidade de classificação e passar adotar regiões obtidas por segmentação prévia da imagem. Buscando introduzir no processo de classificação variáveis que pudessem se adequar a essas novas características, o presente estudo propõe-se investigar a utilização de atributos de forma e textura em adição aos atributos espectrais. Para poder avaliar a eficácia de cada atributo no processo de classificação, será utilizado um algoritmo de classificação em múltiplos estágios e entre os possíveis critérios de separabilidade será utilizada a distância de *Bhattacharyya*. A aplicação do algoritmo proposto foi testado sobre os dados imagem do sistema *Quickbird* e a implementação em ambiente *Matlab*.

¹ Dissertação de Mestrado em Sensoriamento Remoto, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Curso de Pós-Graduação em Sensoriamento Remoto e Meteorologia da Universidade Federal do Rio Grande do Sul, Porto Alegre, maio de 2006.

HIERARCHICAL OBJECT-ORIENTED CLASSIFICATION FOR IMAGES OF HIGH SPATIAL RESOLUTION USING SPATIALS AND SPECTRALS DATAS²

Author: **Marlos Henrique Batista**
Advisor: **Prof. Vitor Haertel Ph.D.**

High spatial resolution image data are becoming increasingly available to the users community. The obvious advantages introduced by high resolution data also pose some new challenges. Chief among them is the problem of digital image classification. The traditional pixel based classification procedures frequently yield poor results when applied to high spatial resolution image data. The small ground pixel size frequently captures an unnecessary high level of detail resulting in large class-variances which increase the confusion among classes. In this context, it is normally more convenient to replace individual pixels by image segments, also known as objects, as individuals to be labeled according with the existing classes. One of the main advantages of employing smaller pixels is the ability of capturing spatial information such as shape and texture which may be conveniently added to the spectral data to increase the accuracy in the resulting thematic map. In this study, it is investigated the combined use of spectral and spatial attributes in a classifier. As the data dimensionality may increase substantially due to the larger amount of data used, a feature extraction process are used in the classification procedure, rather than the original spectral and spatial data themselves. A binary decision tree classifier is used in this study to label every image segment. In a binary tree, only two classes are considered at a time on every node. The feature extraction procedure has to optimize the distance between a pair of classes. In this study, the criterion used to define the linear transformation for feature extraction is the Bhattacharyya distance.

The proposed methodology is tested using high spatial resolution image data acquired by the sensor system Quickbird. Results are presented and commented.

² Master of Sciences Dissertation in Remote Sensing, Center for Remote Sensing and Meteorology, Graduate Program in Remote Sensing at Federal University of Rio Grande do Sul, Porto Alegre, may 2006.

INTRODUÇÃO

A inserção de novos formatos de informações, adquiridos por uma nova geração de sensores remotos orbitais promulgam a investigação de soluções, antes tomadas como referência e agora não mais suficientes. Entre os avanços ocorridos mais recentemente, pode-se destacar o incremento nas resoluções espacial e espectral em dados imagem, criando condições para a incorporação de informações adicionais ao processo de classificação. Dados imagem em alta resolução espacial, como os fornecidos pelos sistemas *Ikonos* e *Quickbird*, com resolução até a ordem centimétrica tornam possível a introdução no processo de classificação, de atributos espaciais, como por exemplo, textura da imagem. Para o processamento e análise dessas imagens, soluções combinadas e/ou individuais são propostas no campo do processamento digital de imagens e do reconhecimento de padrões.

Métodos intensivamente estudados para classificação de imagens digitais agora tendem a ser redesenhados, incorporando novas variáveis no processo. Assim, com o objetivo de apresentar uma nova solução para classificação de imagens digitais de sensoriamento remoto com alta resolução espacial, uma proposta com o uso da segmentação orientada a regiões e da classificação hierárquica baseada em objetos é investigada nesta dissertação.

Os processos de classificação de imagens de sensoriamento remoto tem tradicionalmente feito uso de atributos espectrais unicamente. Nesta abordagem, a unidade de informação é o *pixel*. Este fato deve-se a facilidade com que informações de natureza espectral (radiância) podem ser quantificadas. Uma classificação baseada nessas características é dita como baseada em *pixels*.

A partir da constituição dos satélites de baixa órbita, com alta resolução espacial, tipo *Ikonos II* e *Quickbird* (4 e 2,4 metros respectivamente, para as bandas multiespectrais) foram apresentados novos desafios / características quanto às pesquisas de reconhecimento de padrões.

O principal problema que se verifica na utilização de dados imagem em alta resolução espacial consiste na captura excessiva de variações espectrais internas das classes, funcionando mais como ruído e aumentando desnecessariamente a variância interna das classes. Estas características geram prejuízos no processo de classificação, pois aumentam o erro de *Bayes* e conseqüentemente pioram a acurácia da classificação. Por isso, a necessidade de abandonar o *pixel* como unidade de classificação e passar a adotar regiões (objetos) obtidas por segmentação prévia da imagem.

Adicionalmente, a alta resolução espacial promove uma valorização da informação fornecida por atributos espaciais (forma, textura, etc.) que são de difícil caracterização quando comparado aos dados imagem de satélite de média resolução espacial, como as fornecidas pelo sistema *Landsat-TM* ou *SPOT* (30 e 20 metros respectivamente, para as bandas multiespectrais). Assim, a alta resolução espacial trouxe uma nova visão à tona, fomentando desafios para o desenvolvimento de novas metodologias, buscando introduzir no processo de classificação, variáveis que pudessem se adequar a essas novas características.

Buscando introduzir ao processo de classificação variáveis que pudessem se adequar a essas novas características, a presente dissertação propôs-se investigar a utilização de atributos de forma e textura em adição aos atributos espectrais no processo de classificação. Desta forma, foram criadas para uso no classificador, “bandas” ou

layers adicionais, contendo informações a respeito de atributos espaciais da imagem, como forma e textura. Estas novas “bandas” são então implementadas conjuntamente com as bandas espectrais originais no processo de classificação.

Para poder avaliar a eficácia de cada atributo ou de um conjunto de atributos no processo de classificação, utilizou-se um algoritmo de classificação em múltiplos estágios, em especial o classificador de decisão em árvore (CDA). A estrutura do CDA será apresentada na forma de uma hierarquia binária, de modo que somente duas classes sejam consideradas em cada estágio (nó). Essa estrutura apresenta a vantagem de permitir uma seleção mais adequada para dados espectrais e espaciais em cada um dos nós. Em lugar de selecionar o conjunto de “bandas” espectrais / espaciais que ofereçam a maior separabilidade entre a totalidade das classes, como em um classificador em estágio único, um CDA binário permite que em cada nó seja utilizado um conjunto próprio de bandas, aquele que apresentar a maior separabilidade entre as duas classes tratadas no nó. Nesta abordagem, para a escolha do par de classes a ser tratado em cada nó individual do CDA, utilizou-se o critério de máxima separabilidade, isto é, entre os vários possíveis pares de classes optou-se por aquele em que as classes apresentavam a maior separação, conforme estimada pela distância de *Bhattacharyya*. Entre os vários possíveis critérios de separabilidade utilizou-se o critério da distância de *Bhattacharyya* máxima.

Para utilização conjunta e otimizada dos atributos espectrais e espaciais no processo de classificação, foram selecionados por um processo de seleção de feições denominado SFS (*Sequential Forward Selection*) um subconjunto de feições em cada nó, que melhor caracterizam o par de classes que apresentar a maior separabilidade encontrada pelo critério da distância de *Bhattacharyya* máxima.

A aplicação do algoritmo proposto foi testado sobre os dados imagem do sistema *Quickbird*, com as bandas multiespectrais e pancromática e a implementação do algoritmo foi realizada em ambiente *Matlab*. Os dados imagem do sistema *Quickbird* possuem uma cobertura espectral em três faixas do visível, uma no infra-vermelho próximo e uma faixa pancromática que vai desde o visível até o infra-vermelho

próximo. A resolução espacial destes dados imagem é de 0.6 metros para a banda pancromática e de 2.4 metros para as demais bandas. Estes dados imagem estão quantizados em 11 bits.

Como delineação para constituição dos trabalhos proferidos, objetivou-se pesquisar os seguintes temas:

- A utilização conjunta de atributos espaciais e espectrais no processo de classificação de imagens digitais de sensoriamento remoto com alta resolução espacial, em classificadores paramétricos de estágios múltiplos.
- O poder discriminante de atributos espaciais e espectrais no processo de classificação de dados de sensoriamento remoto em alta resolução espacial.
- As técnicas de seleção de feições conjuntamente a partir de atributos espectrais e espaciais.
- A eficiência de classificadores em estágio múltiplo no processo de classificação orientada a objetos, empregando atributos espaciais e espectrais.

A estrutura desta dissertação está dada da seguinte forma: Capítulo 1: Introdução; Capítulo 2: Revisão Bibliográfica; Capítulo 3: Metodologia; Capítulo 4: Experimento; Capítulo 5: Conclusão, Referências Bibliográficas e Anexos.

No Capítulo 2 estão apresentados a evolução dos dados de sensoriamento remoto importando continuamente o fator resolução espacial, suas principais características e utilizações, confrontação com dados de resoluções espaciais distintas, definições resolução espacial x resolução espectral, e a proposição dos métodos para processamento e modelagem atualmente empregados. Estão caracterizados ainda, os

métodos de classificação em estágio único e em estágio múltiplo e a solução proposta para utilização dos dados de alta resolução espacial de sensoriamento remoto.

No Capítulo 3 apresentam-se os métodos de processamento de imagens e reconhecimentos de padrões utilizados nesta dissertação. Inicialmente são localizados os principais métodos de segmentação, em especial da segmentação baseada em objetos, pelo método denominado de multiresolução. Em seguida, a descrição dos atributos espectrais e espaciais para caracterização dos objetos e o modo de tratamento para sua utilização combinada no processo de classificação, apresentado os principais métodos de seleção de feições.

No Capítulo 4 estão apresentados os experimentos realizados, os materiais utilizados, a área de estudo, o plano de trabalho seguido, os métodos de segmentação e de classificação utilizados, a descrição dos atributos e sua significância individual e combinada no processo de classificação, os classificadores de decisão em árvore e as acurácias encontradas.

O Capítulo 5 apresenta as conclusões referentes aos resultados encontrados no processo de classificação em múltiplos estágios baseados em objetos, utilizando atributos espaciais e espectrais sobre dados imagem de alta resolução espacial, análises comparativas e sugestões para trabalhos futuros.

REVISÃO BIBLIOGRÁFICA

2.1. EVOLUÇÃO DOS DADOS DE SENSORES REMOTOS

Os sistemas sensores remotos ascenderam, principalmente na última década, uma variedade extensa de novas proposições estruturadas segundo especificidades técnicas de cada sensor.

O início dos sensores remotos imageadores foi formatado por estudos incentivados pela iniciativa militar, com o objetivo de espionagem. No final do século XIX e início do XX ocorreram grandes avanços através dos novos conhecimentos sobre a teoria eletromagnética e a física das radiações. Dentro deste contexto se deram as primeiras aplicações da fotogrametria e do imageamento aéreo, aplicadas ao planejamento tático militar, consolidados através de avanços militares trazidos pela primeira grande guerra e os positivos resultados obtidos nos campos de batalha, através de um melhor conhecimento do campo inimigo, o sensoriamento remoto conquistou espaço como uma importante ferramenta ao estudo de atributos espaciais. A utilização destas imagens promoveu o aprimoramento da fotogrametria, fotointerpretação e o desenvolvimento de sistemas radar e outros mais aprimorados para estes fins, nas décadas posteriores.

As práticas das aplicações sobre os dados dos sensores remotos, incentivaram pesquisas em diversas áreas científicas, e em meados da década de 50, pesquisas de *Colwell* mostraram aplicações com o uso de filmes fotos-sensíveis em comprimentos de ondas distintos do espectro eletromagnético, com aplicação especial do infravermelho, o que possibilitou o imageamento noturno (BARRETT & CURTIS, 1992; CAMPBELL, 1996). A partir deste período, alicerçados pela guerra fria e a então corrida espacial, com o advento de pesquisas sobre tecnologias espaciais e sobre novos sensores, utilizou-se pela primeira vez o termo sensoriamento remoto. Novos sensores foram desenvolvidos e colocados em órbita, incrementando inúmeras aplicações para meteorologia, mapeamento topográfico, ambiental, etc.

Os primeiros satélites colocados em órbita foram lançados no final da década de 50 e no início da década de 60. Estes satélites eram dedicados essencialmente à meteorologia e possuíam resolução radiométrica na ordem de 4 bits, cobertura espectral sobre pequenas faixas do visível e do infra-vermelho e resolução espacial na ordem de quilômetros. Os principais satélites deste período são os disponíveis pela série *Tiros* e *Nimbus*.

Aos poucos, foram incrementadas novas resoluções, possibilitando estender as aplicações às componentes do oceano, do solo e da atmosfera. Com a expansão da exploração espacial e de novas tecnologias no segmento da informática, tornou-se possível com o lançamento dos satélites de órbita polar, obter informações da Terra com resolução espacial na ordem de dezenas de metros, já na década de 70. Inicialmente estes dados foram disponíveis pelo satélite *ERTS (Earth Resources Technology Satellite)*, que originou a série *Landsat*.

O desenvolvimento da tecnologia espacial viabilizou na década de 80, o emprego de soluções sofisticadas e a obtenção de dados cartográficos mais precisos com o uso das informações provenientes de sensores orbitais.

Continuamente foram desenvolvidos e colocados à disposição a comunidade civil e militar novos dados de sensores com resoluções espaciais mais altas, delineando

a afinidade técnica às necessidades disciplinares. Para a proposta urbana e para outros fins que necessitavam uma resolução espacial mais alta, no final da década de 90 e no início do presente século, foram projetados novos sensores capazes de fornecer informações de ordem centimétrica e realizar mapeamentos com escalas variando de 1:3000 a 1:5000. Estes sensores têm como característica uma cobertura espectral em três faixas no visível (0.45 a 0.69 μm) e uma no infra-vermelho próximo (0.76 a 0.90 μm) com resolução espacial de 2.4 a 4.0 m, além de uma faixa pancromática cobrindo o intervalo de 0.45 a 0.90 μm , com resolução espacial que varia de 0.61 a 1 m. Sensores com estas características atualmente estão disponíveis nos sistemas *Ikonos II*, *Quickbird* e *Orbview-3*.

2.2. ATRIBUTOS ESPACIAIS: PRERROGATIVAS

A caracterização dos objetos identificáveis em uma imagem pode ser constituída por atributos que os objetos ou uma região apresentam. Ao tentar identificar um objeto sobre uma imagem, cognitivamente utilizam-se atributos que viabilizem a interpretação do modo mais ágil e acessível possível. Quando se analisa um alvo para fins de identificação ou classificação, agregam-se informações previamente conhecidas com características contextuais, temporais, espaciais e espectrais para formar a interpretação do alvo ou região. Essas características são apresentadas na forma de atributos.

Tradicionalmente, os processos de reconhecimento de padrões em dados de sensores orbitais ou aerotransportados utilizam essencialmente atributos com natureza espectral para formação de padrões estatísticos ou determinísticos no processo de classificação, tanto na forma supervisionada como na não-supervisionada.

Conforme a natureza dos alvos naturais ou artificiais que estas imagens apresentam, a utilização de atributos espaciais, caracterizados por atributos de forma,

também chamados de geométricos, e atributos texturais, podem contribuir de modo significativo no processo de reconhecimento de padrões, pela incorporação de informações adicionais às espectrais originais. Para exemplificação destes componentes, está apresentada sobre a Figura 1, uma proposta à fotointerpretação, confrontando algumas classes de informações sobre os dados imagem do sistema *Quickbird*, com resolução espacial de 0.61 m, formada multiespectralmente com essa resolução a partir da execução de processos de fusão de imagens, por substituição da 1ª Componente Principal pela banda pancromática.




Figura 1 – Fotoidentificação dos atributos espaciais e espectrais das classes de informação

Os objetos exemplos, apresentados pela identificação 1 e 2 da Figura 1, são classes compostas essencialmente por elementos de vegetação. O objeto 1 caracteriza elementos da classe vegetação arbórea enquanto que a classe 2 caracteriza elementos da

vegetação rasteira. Essa definição pode parecer inicialmente intuitiva visto a composição que cada uma delas apresenta, porém se analisar de modo mais refinado pode-se constituir alguns elementos discriminantes entre elas, apesar da similaridade entre as características espectrais de ambas. O objetivo consiste, portanto, em analisar os atributos de natureza diversa, de ordem espectral e os que apresentam o potencial de oferecer um poder discriminante maior.

Essa interpretação fornece inicialmente três tipos de atributos que podem ser facilmente caracterizados: textura, forma e contexto. Os atributos de textura podem ser evidenciados pela diferente distribuição espacial nas respostas dos *pixels* em cada um dos dois objetos, mais heterogênea no caso do objeto 1 e mais homogênea no caso do objeto 2. A assimetria é notória quando apresentada pelo objeto 1 e a regularidade geométrica quando analisado o objeto 2, constituindo complementarmente os atributos de forma. Os atributos de contexto são diretamente associados à disposição espacial aonde os objetos estão inseridos. Nesse caso, obtêm-se uma resposta mais imediata sobre a análise do objeto 2, que está inserido a uma área para prática de esportes, podendo caracterizar diretamente como vegetação gramínea.

A fotointerpretação dirigida aos objetos 1 e 2 podem ser estendidas às demais classes de informação. Confrontando os objetos 3 e 4, 5 e 6, e 7 e 8 chegam-se a conclusões similares, utilizando em cada caso determinados conjuntos de atributos e em outros casos, outros, ponderando cada atributo conforme a natureza e a constituição dos objetos das classes.

A proposta no processo de reconhecimento de padrões desta tese segue a diretriz apresentada nessa fotointerpretação, integrar atributos espectrais, comumente utilizados, aos atributos espaciais, criados para o presente fim. Os atributos espaciais utilizados neste estudo estão apresentados na seção 3.2.2 e a visualização na forma de histograma, para os dados imagem do sistema *Quickbird*, de cada variável estão apresentados no Anexo 5.

2.3. RESOLUÇÃO ESPACIAL X RESOLUÇÃO ESPECTRAL

Em reconhecimento de padrões, o objetivo consiste em rotular padrões como membros de uma das classes existentes na cena sendo analisada. No contexto de sensoriamento remoto, existem dois conceitos de classe: (1) classe espectral e (2) classe de informação (ou do usuário). Uma classe espectral é definida por uma função de decisão. No caso de um classificador de natureza estatística, como o abordado nesta dissertação, as funções decisão associadas a cada uma das classes em consideração, incluem uma função de probabilidade. As classes presentes em cenas naturais quase sempre podem ser adequadamente modeladas pela função de *Gauss* (distribuição normal). A classe de informação, por sua vez, apresenta um conceito diferente, consistindo de agrupamentos que apresentam as mesmas características informacionais para o usuário.


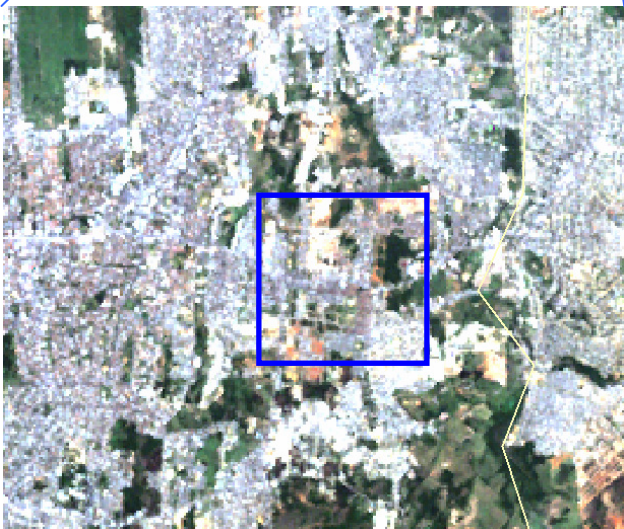
A classe espectral muitas vezes não coincide com a classe de informação, pois o conjunto natural (espectral) dos elementos não é composto pelo conjunto de uma categorização de classes. Por exemplo, uma classe de informação denominada de: edificação com telhado claro, certamente compreende a captação de materiais diversos, ou seja, uma classe de informação contém diversas classes espectrais. A situação ideal seria aquela em que as classes espectrais, que são as tratadas pelo classificador, coincidem com as classes de informação.

Um conceito importante em uma imagem digital consiste de suas resoluções: espacial e espectral. Em termos gerais, entende-se resolução como uma medida da capacidade de um sistema óptico em distinguir individualmente dois sinais que são próximos em termos espaciais, ou similares em termos espectrais. Por resolução espacial entende-se a medida da menor separação (linear ou angular) entre dois objetos tal que ambos possam ser identificados individualmente. A resolução espacial pode ser avaliada pelo tamanho do *pixel*. A resolução espectral diz respeito ao detalhe como são detectadas as variações nas características espectrais de um alvo ao longo das regiões de

interesse do espectro eletromagnético. A resolução espectral é medida pelo número e pela largura das bandas espectrais disponíveis no sistema sensor.

Em dados imagem de média resolução espacial, que apresentam resoluções da ordem de 15 a 30 metros, o comportamento de cada classe espectral é composto pela radiância refletida pelos materiais integrados no campo de visada (IFOV – *instantaneous field of view*) do sistema sensor. Por exemplo, o ambiente urbano em dados imagem de media resolução espacial como os fornecidos pelos sistemas *Landsat*, *Spot*, *Cbers*, *Aster*, dentre outros, são considerados, numa abstração, como pertencente a uma única classe de usuário. Sabe-se que a composição das informações que o ambiente urbano apresenta é altamente variável, compreendendo a captação de diversos materiais, isto é, de diversas classes espectrais, do tipo: sistema viário (asfalto, paralelepípedo, etc.), edificações (telhado de cerâmica, zinco, amianto, etc.), cobertura vegetal rasteira e arbórea, solo exposto, dentre outros.

Confrontando os dados imagem de duas resoluções espaciais diferentes, uma adquirida pelo sistema *Landsat*, com resolução espacial de 30 metros com outra pelo sistema *Quickbird*, com resolução espacial de 0.6 metros, pode-se facilmente verificar as definições espectral e espacial dos objetos sobre a imagem. Para exemplificar pictoricamente este caso, apresenta-se sobre a primeira coluna da Figura 2 diferentes aproximações digitais (*zoom*) de dados imagem obtidos pelo sistema *Landsat* e sobre a segunda coluna, diferentes aproximações de dados imagem obtidos pelo sistema *Quickbird*. Os retângulos em destaque pela cor azul representam as aproximações seguintes e as elipses em vermelho alguns elementos selecionados para orientação visual na comparação espectral e espacial entre os dados imagem. A Figura 2 busca representar essencialmente as classes apresentadas pelo ambiente urbano.

Dados Imagem do Sistema <i>Landsat</i>	Dados Imagem do Sistema <i>Quickbird</i>
<p data-bbox="411 465 576 499">Aproximação 1</p>  <p>The image shows a wide view of a city and surrounding areas. A blue rectangular box highlights a specific urban area in the upper-middle part of the frame. A yellow outline on the left side indicates a water body. Blue lines extend from the corners of the blue box towards the bottom of the page, indicating a zoom-in.</p>	
<p data-bbox="411 1070 576 1104">Aproximação 2</p>  <p>This is a zoomed-in view of the area highlighted in the previous image. A blue rectangular box highlights a smaller, more detailed urban area. The image shows individual buildings and streets. A yellow outline on the right side indicates a boundary or water body.</p>	

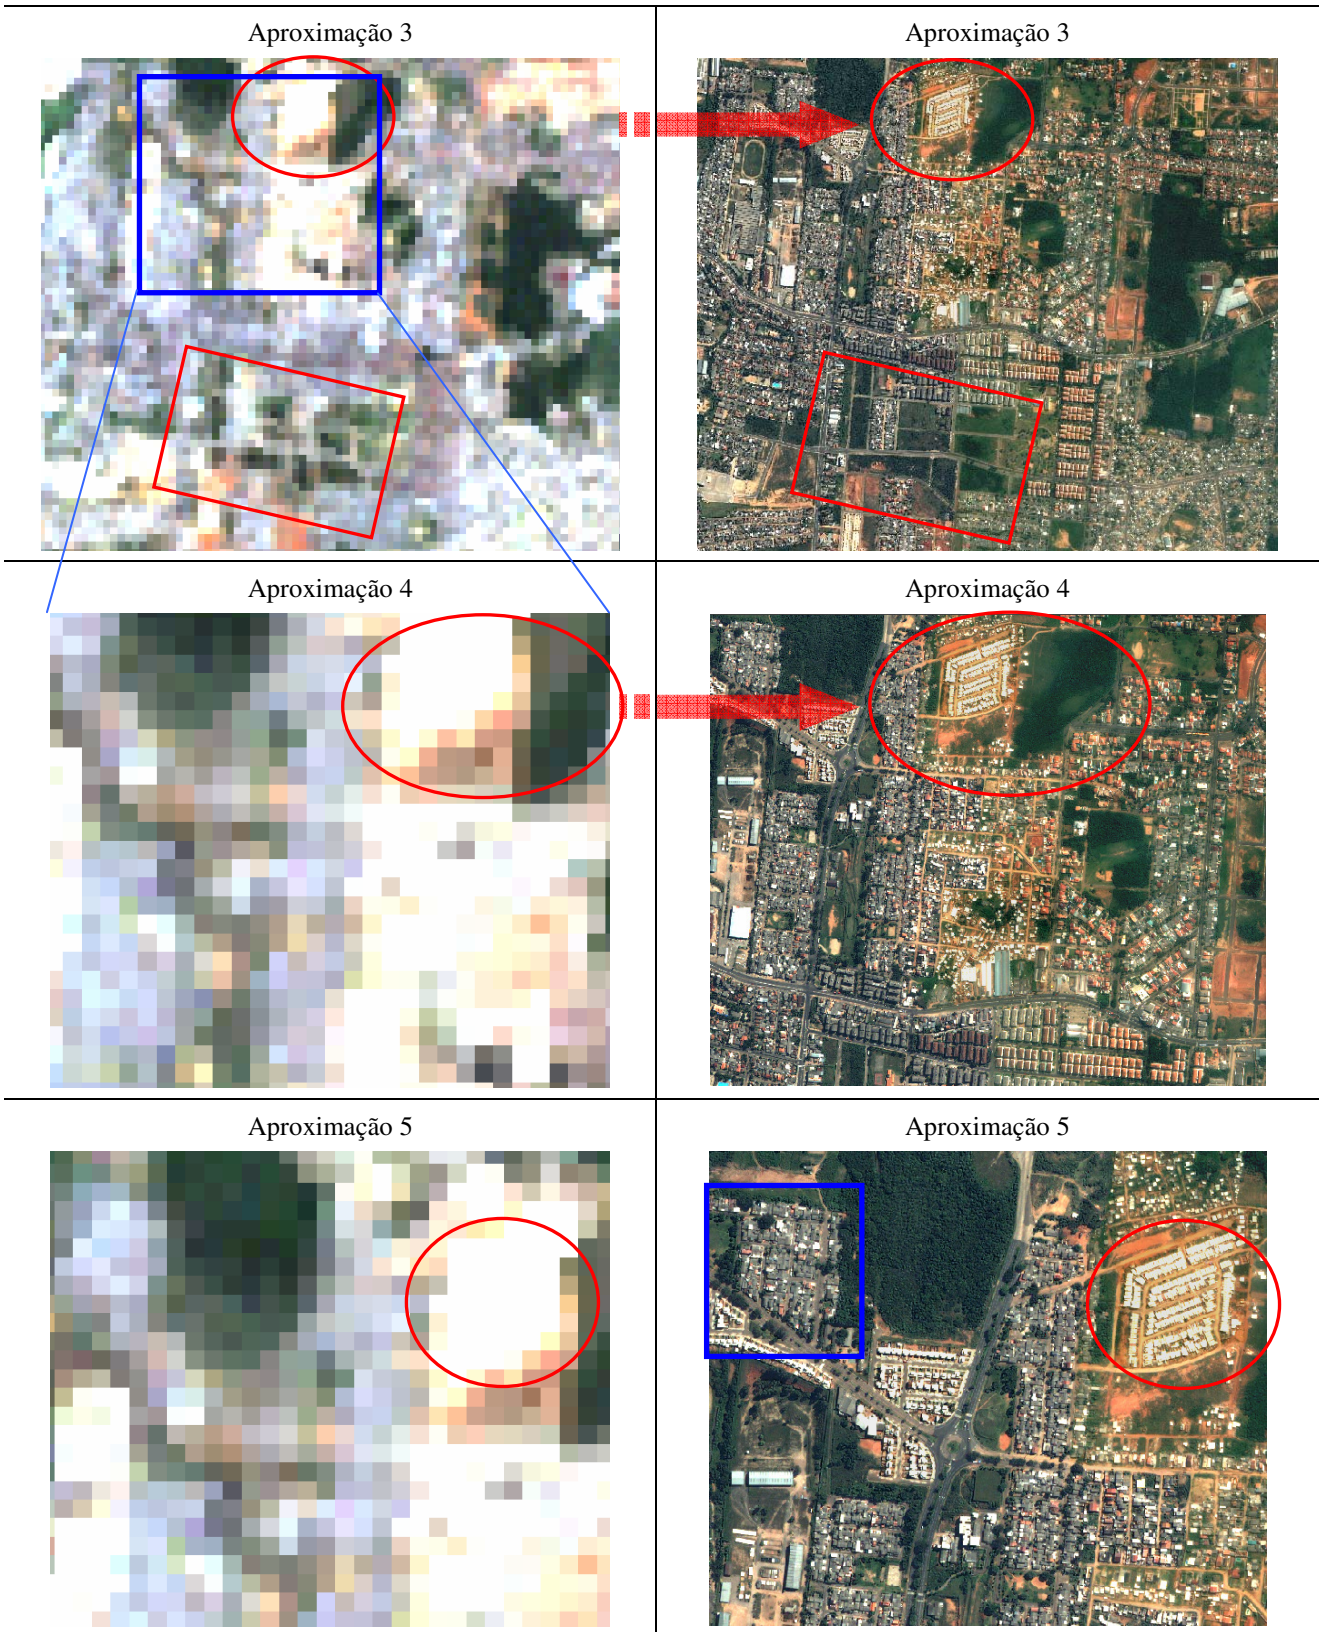




Figura 2 – Confrontação espectral e espacial entre dados imagem dos sistemas *Landsat* e *Quickbird*

Nas aproximações 3, 4 e 5 é possível verificar a generalização realizada pelos dados imagem fornecidos pelo sistema *Landsat* dos elementos espectrais das classes. Nitidamente pode ser estabelecido um paralelo entre a constituição das classes

espectrais dos dados imagem do sistema *Landsat* e *Quickbird*. Como exemplo pode-se verificar, na Aproximação 5, que alguns dos elementos compreendidos pelas classes espectrais de solo exposto que estão distribuídas entre a edificação com telhado claro na região em destaque nos dados imagem do sistema *Quickbird*, são representados em uma única classe espectral nos dados imagem do sistema *Landsat*. Provavelmente sobre uma classe de informação denominada telhado claro.

Os elementos de edificações nos dados imagem do sistema *Landsat* fazem parte de uma mistura espectral, entre informações de solo exposto, vias e vegetação, enquanto que nos dados imagem do sistema *Quickbird* é possível separar cada elemento de edificação, conforme apresentado nas Aproximações 6 e 7 da Figura 2.

Mesmo em dados de média resolução espacial como, por exemplo, dados *Landsat-TM*, nos quais *pixels* individuais consistem freqüentemente da mistura de mais de uma classe espectral, a experiência tem mostrado que é aceitável a modelagem dos mesmos pela distribuição de *Gauss*.

A Figura 3 apresentada o histograma obtido a partir de dados da banda 1 do sistema *Landsat-TM* (0,45 a 0,52 μm) para a classe de informação Área Urbana, com uma resolução espacial de 30 m, do município de Porto Alegre / RS. Os dados apresentados pelo histograma foram definidos por seleção de amostras sobre a imagem. A área hachura em vermelho na imagem de satélite da Figura 3 é um exemplo do dado amostrado, para criação do histograma.

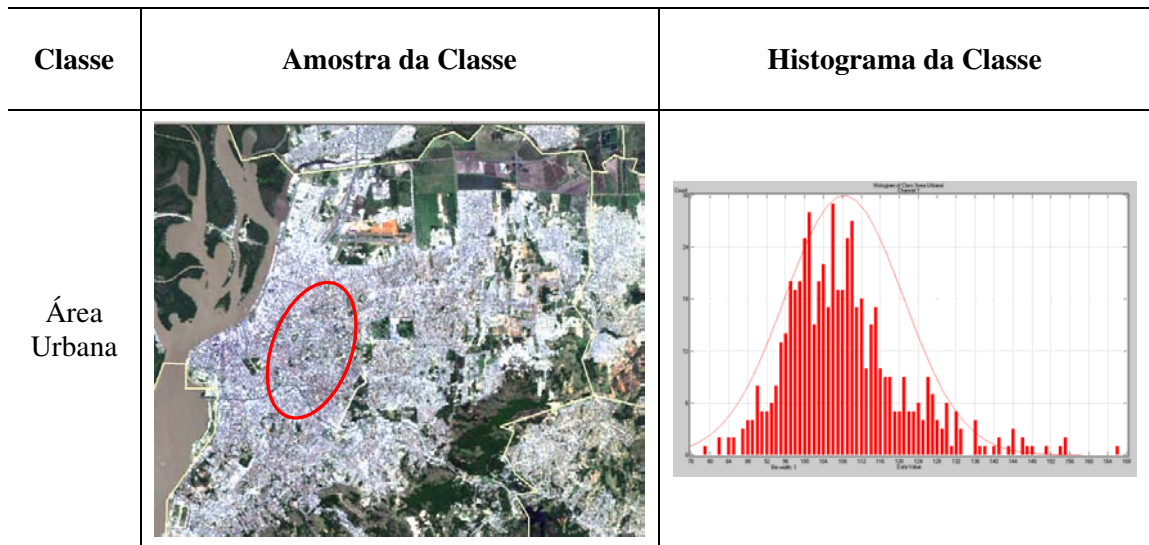


Figura 3 – Exemplo de histograma da classe de informação área urbana de dados imagem do sistema *Landsat*

Ao analisar o histograma da Figura 3, verifica-se que apesar da mistura de classes espectrais para uma determinada faixa espectral, pode-se inferir que existe uma distribuição próxima à normal capaz de modelar os dados amostrados para a classe de informação denominada área urbana.


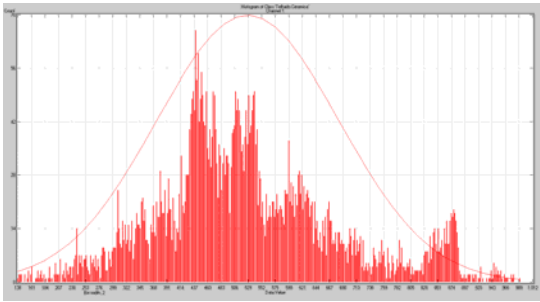
2.4. SOLUÇÕES PROPOSTAS


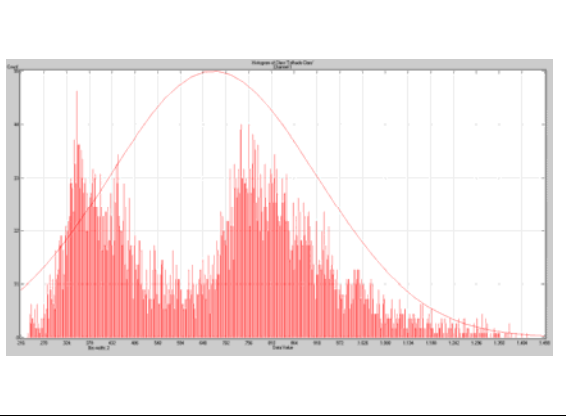

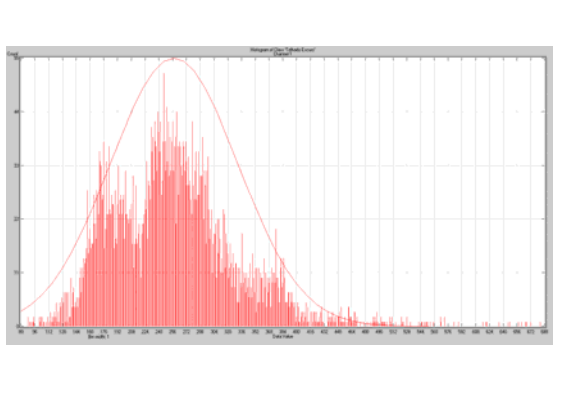

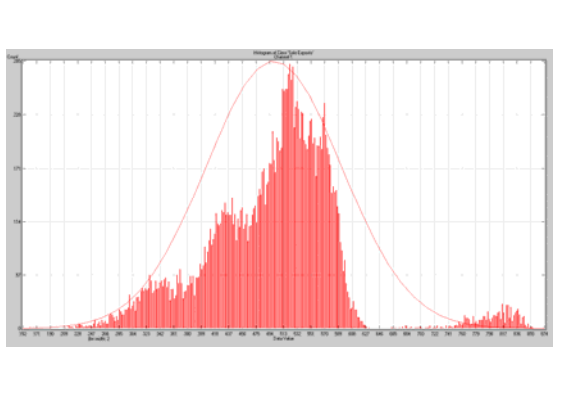

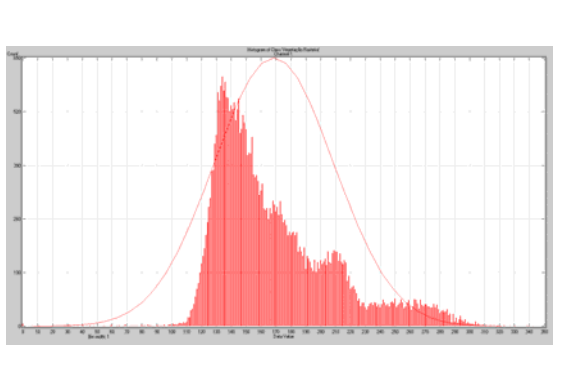
Nos processos de classificação que envolvem abordagens paramétricas é suposto para cada classe a forma da distribuição de probabilidade. Os parâmetros necessários para o modelo são estimados a partir de amostras de treinamento, que permite assim obter aproximações de funções contínuas de densidade de probabilidade (SCHOWENGERDT, 1997).

Em se tratando de dados de sensoriamento remoto de alta resolução espacial, há um acréscimo significativo na variância espectral interna das classes, devido à

variedade e especificidade de elementos captados pelo sensor sobre uma mesma classe, ou seja, com imagens de alta resolução espacial tende-se a ter uma captação de materiais mais específicos dentro de uma mesma classe (aumento da variância) ao invés de uma captação média de vários objetos, quando comparado a sensores de satélites de média resolução espacial. Esse fator aumenta de modo expressivo a variância interna das classes, prejudicando o processo de classificação por métodos paramétricos. No classificador de Máxima Verossimilhança Gaussiana, o aumento da variância interna das classes individuais resulta em um aumento no erro de *Bayes*, degradando a acurácia da imagem temática produzida.

A Figura 4 apresenta os histogramas das classes de informações, de edificação: telhado cerâmica, telhado claro e telhado escuro, de solo exposto, de vegetação: vegetação arbórea e vegetação rasteira e de vias. O padrão definido para representação da imagem foi o *pixel* e as características que ela apresenta são do recobrimento espectral da faixa de 0.45 a 0.52 μm (banda 1), quantizado em 11 bits, com resolução espacial de 0.6 m.

Classe	Amostra da Classe	Histograma da Classe
Edificação Telhado Cerâmica		

<p>Edificação Telhado Claro</p>		
<p>Edificação Telhado Escuro</p>		
<p>Solo Exposto</p>		
<p>Vegetação Rasteira</p>		

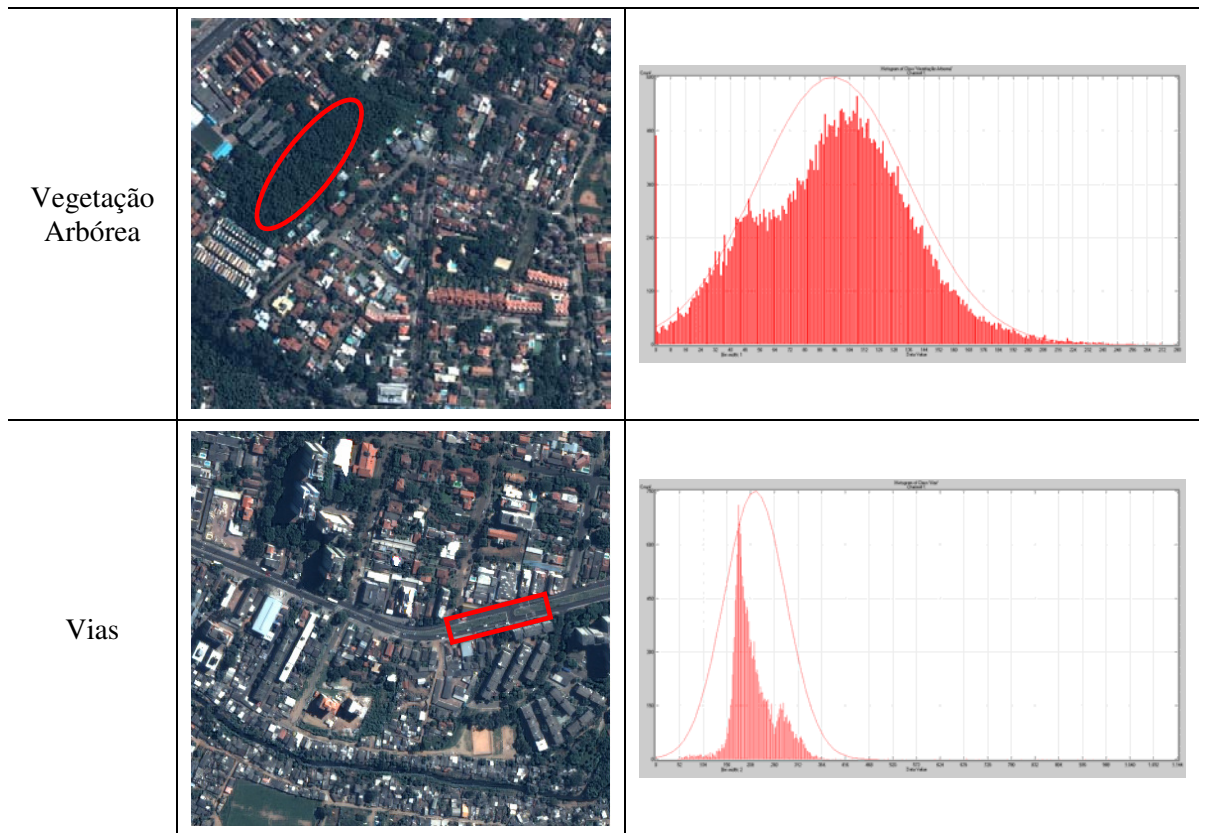


Figura 4 – Histograma de classes de informação de dados imagem do sistema *Quickbird* (padrão: *pixel*)

Analisando os histogramas da Figura 4 pode-se verificar a presença de comportamentos bimodais e multimodais para as classes amostradas, apresentando um alto grau de variação espectral, dificultando a exposição dos dados por definições paramétricas, justificando empiricamente as afirmativas deste capítulo.

Para podermos confrontar os histogramas das classes sobre uma mesma escala, permitindo verificar a discriminação inter-classes estruturou-se a Figura 5 que apresenta os histogramas combinados das classes.

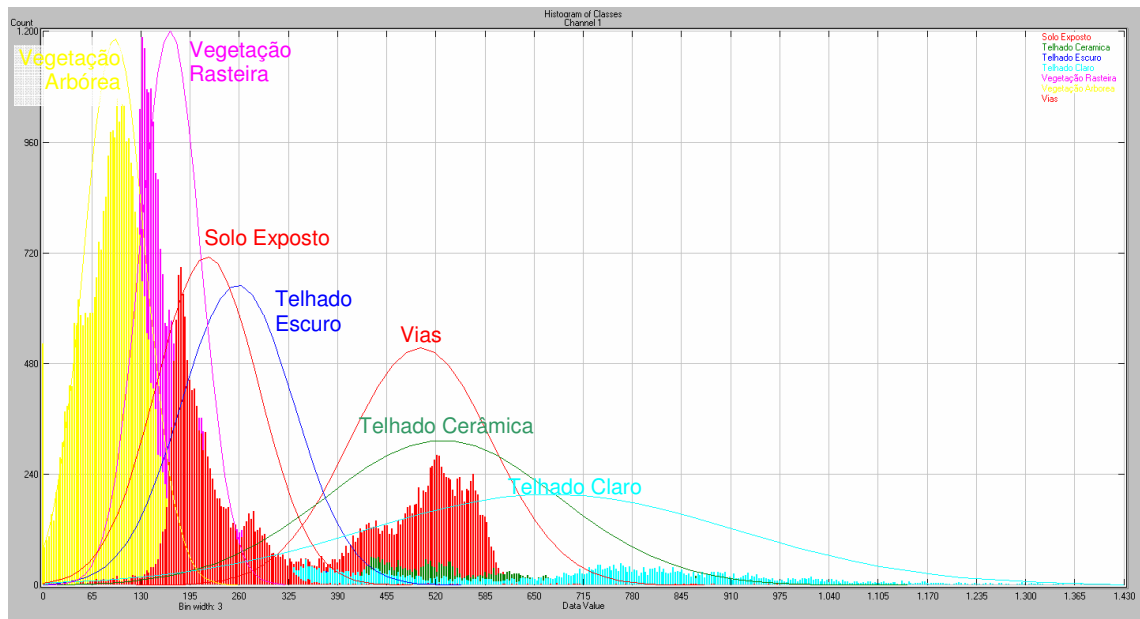


Figura 5 – Histograma combinado de classes de informação dos dados imagem do sistema *Quickbird* (padrão: *pixel*)

A quantificação das variâncias sobre a Figura 5 pode ser visualizada pelos histogramas combinados. Verificando a alta variância para as classes de edificações, em especial, telhado claro e telhado de cerâmica, pode-se prever o prejuízo que isso incitará no processo de classificação. O resultado de uma classificação paramétrica, utilizando a função de máxima verossimilhança realizada utilizando os dados aqui apresentados está apresentado no capítulo 4.8.7.

Duas possíveis soluções a este problema são: classificadores não-paramétricos ou padrões constituídos por segmentos da imagem (objetos) em lugar de *pixels* individuais como vem sendo tradicionalmente feito.

Como a proposta do estudo é a utilização de classificadores paramétricos, há a necessidade então de abandonar o padrão *pixel* e passar a definir outros padrões como unidade de classificação, capazes de estimar as funções densidade de probabilidade de modo a apresentar fatores discriminantes para cada classe. A solução proposta visa

utilizar como padrão objetos, resultantes da segmentação da imagem como nova unidade no processo de classificação. A Figura 6 A apresenta uma imagem em formato unicamente matricial e a Figura 6 B uma imagem com os objetos derivados do processo de segmentação.



Figura 6 – Objetos criados por segmentação em dados imagem de alta resolução espacial

Na seção 2.2, ilustrou-se, por meio de um exemplo, o ganho discriminante apresentado pelos atributos espaciais (textura, contexto, geometria), criando desta forma uma justificativa para a incorporação de atributos espaciais ao processo de classificação de dados imagem com alta resolução espacial.

Resumindo, o objetivo nesta dissertação visa a utilização combinada de atributos espaciais, em especial atributos geométricos e de textura, e de atributos espectrais, mais tradicionalmente utilizados. Nesta abordagem, os padrões a serem classificados são segmentos da imagem, conhecidos pela designação genérica de *objetos* e obtidos por uma prévia segmentação da imagem.

2.5. MÉTODOS DE CLASSIFICAÇÃO

O processo de classificação de uma imagem utiliza métodos estudados em reconhecimento de padrões e tem por objetivo atribuir *pixels* ou regiões individuais a uma das classes existentes. Uma classe é definida por meio de critérios que servem para caracterizar os indivíduos que nela se encontram. Estes critérios podem ser caracterizados em termos de atributos espectrais e/ou espaciais. Existem diversas abordagens com relação aos processos de classificação. A abordagem denominada de paramétrica será utilizada neste estudo. Nos métodos paramétricos, é definida uma função discriminante para cada uma das classes envolvidas no processo. Estas funções discriminantes são baseadas em funções densidade de probabilidade, que utilizam um número relativamente pequeno de parâmetros a serem estimados a partir de amostras disponíveis para cada classe (BOW, 1992).

O processo de classificação consiste em inicialmente decidir sobre a forma geral da função de decisão a ser utilizada. Em uma segunda etapa, os parâmetros que constam nesta função decisão são estimados para cada uma das classes presentes na cena sendo analisada, gerando desta forma, para cada classe individual w , uma particular função de decisão $G(X)$. O processo de classificação (ou rotulagem) de padrões individuais (*pixels* ou objetos) consiste em aplicar a regra abaixo:

Regra de Classificação:

$$X \in w_i \quad \text{se} \quad G_i(X) > G_j(X) \quad \forall \quad i \neq j$$

Dentre as muitas propostas de função discriminante apresentadas, quando se tratando de dados de sensoriamento remoto, a regra de decisão denominada de Máxima Verossimilhança Gaussiana (MVG), que é um caso particular do classificador de *Bayes*, tem modelado de forma aceitável a distribuição dos dados.

2.5.1. Classificador de Máxima Verossimilhança

Nesta seção é feita uma rápida revisão do classificador Máxima Verossimilhança Gaussiana (MVG).

Nesta abordagem, parte-se da função de probabilidade *a posteriori*:

$$p(w_i|x) \quad i = 1, 2, \dots, m \quad (1)$$

A regra de decisão consiste em:

$$x \in w_i \quad \text{se} \quad p(w_i|x) > p(w_j|x) \quad \forall i \neq j \quad (2)$$

Esta função de probabilidade pode ser expressa de uma forma mais conveniente utilizando-se o teorema de *Bayes*:

$$p(w_i|x) = \frac{p(x|w_i) \cdot P(w_i)}{p(X)} \quad (3)$$

onde $P(w_i)$ é a probabilidade *a priori* para a classe w_i , $p(w_i|x)$ é a probabilidade *a posteriori* da classe i e $p(x|w_i)$ é o valor da função de densidade de probabilidade de X no ponto x observado e substituindo os parâmetros conhecidos por suas respectivas estimativas de máxima verossimilhança.

Sendo a função $p(X)$ comum a todas as classes, pode ser retirada de (3) sem que o resultado do classificador seja alterado, de modo que a regra de decisão (2) fique,

$$x \in w_j \quad \text{se} \quad p(x|w_i) \cdot P(w_i) > p(x|w_j) \cdot P(w_j) \quad \forall i \neq j \quad (4)$$

O resultado da regra de classificação não será alterado se for utilizada uma função monotonicamente crescente de cada termo de (4) e dado que geralmente o pesquisador não possui informação suficiente sobre as probabilidades *a priori* das classes, pode-se considerar pesos iguais para as probabilidades *a priori*.

$$G_i(X) = \ln\{p(x|w_i)\} \quad (5)$$

Assim, a regra de classificação é dada por:

$$X \in w_i \quad \text{se} \quad G_i(X) > G_j(X) \quad \forall \quad j=1, 2, \dots, m \quad (6)$$

Decide-se que X pertence à classe w_i se e somente se $G_i(X) > G_j(X)$ para todo $j = 1, 2, \dots, m$.

A efetiva utilização da função decisão (5), requer que seja definida uma forma específica para a função densidade de probabilidade $f(X|w_i)$. Como apresentado anteriormente, a experiência tem mostrado que em se tratando de dados de sensoriamento remoto, a função de *Gauss* modela de uma forma aceitável a distribuição dos dados. Neste caso $w_i = (M_i, \Sigma_i)$.

Assim, a função densidade de probabilidade de um padrão X , dado uma classe w_i , pode ser escrita por:

$$f(X|w_i) = \frac{1}{(2\pi)^{n/2} |\Sigma_i|} \cdot \exp\left(-\frac{1}{2} \cdot (X - M_i)^T \Sigma_i^{-1} (X - M_i)\right) \quad (7)$$

Permitindo que a função decisão (5) fique:

$$G_i(X) = \frac{P(w_i)}{(2\pi)^{n/2} |\hat{\Sigma}_i|} \cdot \exp\left(-\frac{1}{2} \cdot (X - \hat{M}_i)^T \hat{\Sigma}_i^{-1} (X - \hat{M}_i)\right) \quad (8)$$

Onde \hat{M}_i e $\hat{\Sigma}_i$ são as estimativas de máxima verossimilhança de M_i e Σ_i , respectivamente.

Sendo assim, a regra de classificação utilizando a densidade de *Gauss* na forma simplificada fica (RICHARDS, 1998):

$$G_i(X) \propto -\ln|\hat{\Sigma}_i| - (X - \hat{M}_i)^T \hat{\Sigma}_i^{-1} (X - \hat{M}_i) \quad (9)$$

A denominação de classificador de máxima verossimilhança deve-se ao fato de se utilizar o estimador de máxima verossimilhança na regra de classificação.

2.5.2. Classificador Discriminante Linear de Fisher

Uma simplificação da função de verossimilhança é a função discriminante linear de *Fisher*. Essa função considera a mesma matriz de covariâncias para todas as classes. A equação discriminante é dada então por RICHARDS (1998) como:

$$G_{F_i}(X) \propto (X - \hat{M}_i)^T \hat{\Sigma}^{-1} (X - \hat{M}_i) \quad (10)$$

2.5.3. Classificador da Distância Mínima Euclidiana

O classificador da distância euclidiana mínima é um caso particular da função de verossimilhança, partindo das premissas que as probabilidades *a priori* e as matrizes de covariâncias são iguais e diagonais, e não há existência de correlações (RICHARDS, 1998). Esse predicado faz com que a definição da pertinência de um padrão a uma classe pelo classificador da distância mínima euclidiana utilize exclusivamente a média sobre a função de decisão.

Assim, a função discriminante para a distância mínima euclidiana é dada por:

$$G_{D_i}(X) \propto (X - \hat{M}_i)^T (X - \hat{M}_i) \quad (11)$$

2.5.4. Comparação entre os Classificadores

Comparando a função discriminante de distância mínima euclidiana à máxima verossimilhança, apresentados num espaço multiespectral, onde cada classe espectral ocupa uma determinada região, pode-se dizer que o classificador de MVG apresenta maior poder discriminante (de definição e particionamento) do espaço multiespectral que a distância mínima euclidiana. A mesma referência pode ser estendida quanto à comparação ao classificador linear de Fisher e o de MVG.

2.6. CLASSIFICADORES DE DECISÃO EM ÁRVORE

A necessidade de encontrar novos sistemas de reconhecimento mais robustos e eficazes, capazes de identificar padrões cada vez mais complexos, com orientação, localização e escalas próximas do aleatório, tais como, reconhecimento de faces, pesquisa *web*, padrões do ambiente urbano, dados multimídia, incitaram pesquisas sobre redes neurais, teoria da evidência, *support vector machine* e classificadores hierárquicos.

Classificadores de decisão em árvore (CDA) podem ser vistas como um modo de representar um conjunto de regras sobre uma seqüência hierárquica, estruturada de modo a particionar recursivamente os dados. Os CDA's são formados por *n*-ésimas ramificações de uma árvore, que representam regras de classificação, definidas para classificar os padrões de um determinado domínio em uma configuração de classes mutuamente exclusivas.

Atualmente os CDA's estão dispostos às aplicações em diversas áreas do conhecimento, abrangendo métodos, complementação de técnicas e algoritmos para o reconhecimento de caracteres e padrões, sensoriamento remoto, diagnósticos médicos, sistemas especialistas, dentre outros. Contudo, a mais importante função de um CDA, conforme BREIMAN *et al.* (1984) é a sua capacidade de converter processos de decisão complexos em uma série de decisões simples.

A proposta básica em qualquer abordagem em estágios múltiplos, conforme citado, é a desagregação de regras de decisões complexas em um conjunto de decisões simples, de modo que, o resultado se mantenha inalterado, sendo qualquer que seja o modelo de decisão adotado.

A estrutura geral de um CDA segue conforme a definição de SAFAVIAN & LANDGREBE (1991) na Figura 7.

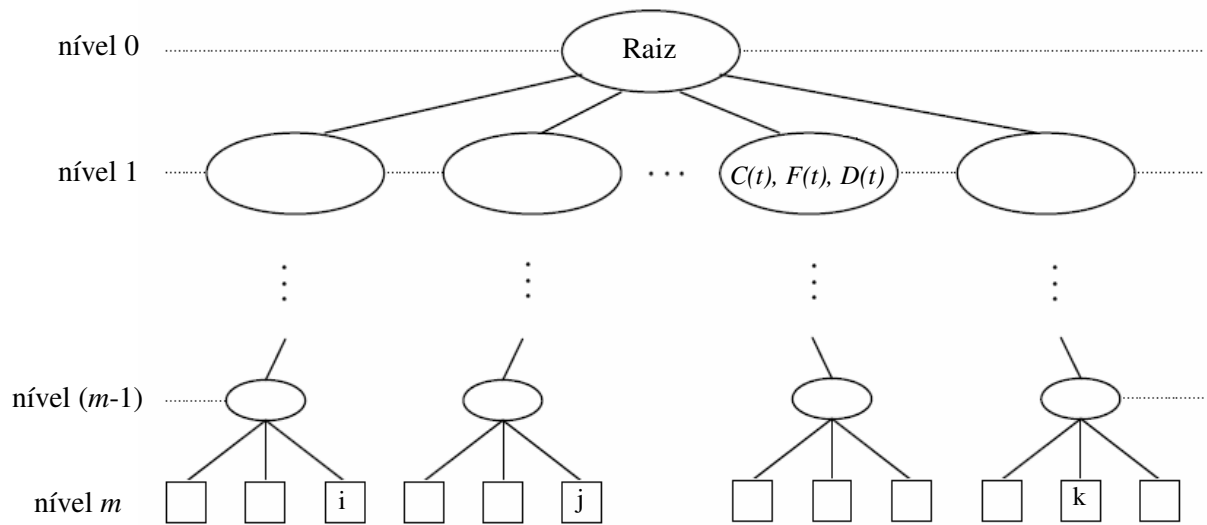


Figura 7 – Estrutura geral de um classificador de decisão em árvore.
Adaptado de SAFAVIAN & LANDGREBE (1991)

No nível 0 está localizado o nó raiz, o início da árvore. O nó raiz contém todos os padrões de todas as n classes a serem classificados pelo CDA. Nos nós seguintes estão apresentadas as derivações do nó raiz sobre cada ramo da árvore, definidos por três componentes, também chamado de terna:

- a) Uma regra de decisão;
- b) Um conjunto específico de feições (variáveis);
- c) Um conjunto específico de classes.

Cada nó está aqui representado por t e está composto por uma terna $(C(t), F(t), D(t))$, onde $C(t)$ representa as classes do nó t , $F(t)$ as feições usadas pelo nó t e $D(t)$ a regra de decisão do nó t . O processo de discriminação dos padrões no CDA utiliza em cada nó uma regra de decisão sobre um conjunto de feições para tentar discriminar um determinado conjunto de classes. Esse processo pode ser considerado como o crescimento da árvore.

Os nós apresentados pelo nível m , onde m é o número total de níveis, são chamados de nós terminais. Neste nível apenas uma classe é representada no nó, não possibilitando realizar mais o processo de crescimento da árvore, como utilizado pelos demais nós nos ramos da árvore. No nó terminal o padrão agora discriminado, recebe a identificação (rótulo) da classe do nó.

Uma vantagem expressiva que o CDA apresenta é a permissão de que classes apresentadas em estágios intermediários do processo de classificação sejam rejeitadas, fazendo com que um padrão seja exposto a um número reduzido de classes, diminuindo o erro de *Bayes*, otimizando significativamente o desempenho do classificador e o tempo de processamento. Outras potencialidades foram apresentadas por SAFAVIAN & LANDGREBE (1991) em referência ao CDA, citando principalmente a forma otimizada dos algoritmos de modelos de decisão e sua performance computacional e a melhora no desempenho discriminante do classificador.

Para poder ter uma base de referência qualitativa dos classificadores em estágios múltiplos (CEM), em especial do CDA, avalia-se uma contraposição das potencialidades, equiparadas aos classificadores em estágio único (CEU). Inicialmente, decisões globais complexas apresentadas pelos CEU podem ser substituídas por um conjunto de decisões locais simples, por exemplo, estruturadas por um CDA, desagregando-as sobre vários níveis da árvore. Nos CEU's cada dado amostrado é testado sobre um conjunto completo de todas as classes, já nos CDA's, cada amostra é testada sobre subconjunto de classes, otimizando a performance computacional e o desempenho do classificador.

Os CEU's utilizam somente um conjunto de feições para discriminação das classes. A seleção deste conjunto de feições é feita por um critério de otimização global, utilizando uma medida de separabilidade para todo o conjunto de classes. No CDA é possível ter diferentes conjuntos de feições sobre cada nó de uma árvore, aquela que apresentar a discriminação ótima para o subconjunto de classes do nó, diminuindo a probabilidade de erro na classificação. Neste caso a separabilidade pode ser considerada como sub-ótima ou ainda como ótima, no caso de comparação entre um par de classes.

As medidas de separabilidade utilizadas em ambos os casos podem ser as mesmas, como por exemplo, a divergência euclidiana, a distância de *Bhattacharyya*, a distância de *Kolmogorov-Smirnoff*, etc.

Pode-se avaliar, ainda, que com a utilização de um grande número de feições e de classes é apresentada uma degradação no desempenho geral do classificador, devido à necessidade de estimar a distribuição em alta dimensionalidade, tendo um número reduzido de amostras. Este problema é amenizado com o CDA, pois nesta abordagem fica mais fácil identificar um subconjunto ótimo de variáveis e portanto de reduzir a dimensionalidade dos dados.

Atualmente a bibliografia apresenta inúmeros relatos de sucesso utilizando CEM, para aplicações em diferentes áreas, tais como: mapeamento de cobertura vegetal (SIMARD *et al.*, 2000) e (KOUSKOULAS *et al.*, 2004) e a dinâmica do espaço urbano (PAVULURI *et al.*, 2002).

Um dos problemas que os CDA's podem apresentar é em relação à sobreposição de classes. Quando o número de classes é relativamente grande, pode haver uma quantidade de nós terminais muito maiores que o número classes, aumento o custo de processamento. KURZYNSKI (1983) e BREIMAN *et al.* (1984) apresentam as dificuldades de modelar uma estrutura de CDA ótima, pois se sabe que o desempenho de um CDA está fortemente associado à estrutura de árvore utilizada.

Um classificador não é construído sem que haja um objetivo, eles estão baseados em experiências passadas. A construção de um classificador impõe este aprendizado como pré-requisito, podendo inferir assim, que parte do processo é empírico ou baseado em relatos da literatura. RICHARDS (1998) e WU & LANDGREBE (1975) mostram ainda, que os CDA's podem apresentar erros cumulativos, propagando-se de nível para nível, o que requer cuidados com relação à estrutura de árvore utilizada e ao método de abordagem sobre o CDA.

2.7. MODELOS DE CLASSIFICADORES DE DECISÃO EM ÁRVORE

Vários modelos para CDA's estão propostos na literatura. Uma revisão bastante completa pode ser encontrada em SAFAVIAN & LANDGREBE (1991). Nesta dissertação é empregada a abordagem denominada de *bottom-up* do tipo binário.

Nesta abordagem, uma árvore binária é construída partindo de um conjunto contendo todas as classes, dispostas no nó raiz. Através das amostras de treinamento de um conjunto de feições das classes é estimada uma medida de separabilidade com o objetivo de identificar o par de classes que apresentar a maior distância entre as suas componentes. Estas duas classes são então utilizadas na definição das regras de decisão que irão caracterizar os dois nós descendentes. Este procedimento repete-se a cada nó, até que os nós terminais (constituídos por apenas uma classe) sejam atingidos.

A discriminação, nesta abordagem é mais significativa quanto menor for o nível da árvore, ou seja, quanto mais próximo estiver da raiz. A discriminação é mais suave quanto mais próximo estiver do nível m , próximo ao nó terminal. LANDEWEERD *et al.* (1983) justificou empiricamente essa afirmação.

A abordagem *bottom-up* está altamente empregada nos processos atuais, com a proposta original ou por derivações. BREIMAN *et al.* (1984) utilizou-a no conceituado algoritmo CART (*Classification and Regression Trees*), com uma estrutura de particionamento de classes, de modo a incrementar a pureza dos dados originais.

A principal vantagem que a abordagem *bottom-up* do tipo binário apresenta é que somente duas classes são consideradas em cada nó, fornecendo um ganho representativo ao permitir a seleção mais propícia das feições em cada nó, ao invés de selecionar do conjunto total de feições, a com maior separabilidade entre a totalidade de classes. Isso proporciona uma maior acurácia no processo de classificação, pois minimiza o risco de *Bayes*.

METODOLOGIA

3.1. SEGMENTAÇÃO

O objetivo de um processo de segmentação é o de dividir uma imagem em regiões, baseado em uma ou mais características que a imagem pode apresentar. Cada região é considerada como um objeto da imagem, estruturada segundo as propriedades de conectividade intra-objetos, intersecção nula e portadora de uma característica comum para todos os contadores digitais de uma mesma região, para toda a imagem.

GONZALEZ & WOODS (1993) exprimem que a proposta da segmentação é o particionamento de uma imagem em regiões até a obtenção do isolamento dos chamados objetos ou regiões de interesse, as quais são funções diretas do problema considerado.

As regiões de interesse, associados às resoluções espacial e espectral, vão promover a definição do método de segmentação e quando afins, podem constituir objetos definidos fieis à qualificação e quantificação das feições reais representadas na imagem. Essa representação serve como fator limitante à qualidade da posterior etapa de classificação.

Portanto, a escolha do método de segmentação e de seus parâmetros internos, deve ser proferida a partir de um estudo rígido das características intrínsecas da imagem e dos objetos de interesse, devido à inerência que os segmentos bem caracterizados possuem em uma classificação orientada a objetos bem sucedida.

3.1.1. Métodos de Segmentação

Pode-se considerar que a segmentação ideal é aquela que utiliza um método, sendo este o mais autônomo possível e que extraia com exatidão as regiões de interesse. Partindo deste pressuposto, um método de segmentação tenta buscar o equilíbrio entre a automação e a exatidão na extração das regiões de interesse. É aceitável que o esperado equilíbrio muitas vezes não seja alcançado, devido à heterogeneidade das regiões de interesse e a infinda possibilidade de soluções à segmentação. Nesse último caso, o processo de segmentação busca diminuir o grau de liberdade para uma ou poucas soluções, já para heterogeneidade das regiões de interesse, a solução é a adoção de um método de segmentação apropriado.

Classicamente os métodos de segmentação podem ser classificados em dois domínios principais: a segmentação baseada em descontinuidades dos contadores digitais (CD's) e a segmentação baseada em similaridade dos CD's (GONZALEZ & WOODS, 1993). A segmentação por descontinuidades está fundamentada em particionar a imagem baseando-se nas mudanças bruscas que os CD's podem apresentar. Assim, a segmentação por descontinuidades busca encontrar fronteiras através de algoritmos de detecção pontos isolados (*Detection Isolate Points*), detecção de linhas (*Detection of Lines*) e detecção de bordas (*Detection Edges*). Estes algoritmos utilizam uma máscara de convolução que percorre a imagem à procura de descontinuidades, como exemplo, pode-se citar uma máscara estruturada para detectar pontos (*pixels*) que apresentem grandes diferenças para com os *pixels* vizinhos. O procedimento pode ser feito utilizando um filtro do tipo passa-alta (filtro para realce) associado a uma regra, que implica que se o resultado da máscara for maior que um determinado limiar ($|R| > T$)

então há uma diferença significativa deste *pixel* para com os demais, ou seja, é uma descontinuidade. Os procedimentos de detecção de linhas e bordas podem ser proferidos a partir de derivações deste.

A segmentação baseada em similaridade dos CD's busca dividir a imagem em regiões de interesse através das propriedades de distribuição dos *pixels*. Os métodos de segmentação por similaridade são tidos frente à comunidade científica como mais eficientes à proposta da segmentação, pois os métodos de detecção por descontinuidade utilizam somente uma característica da imagem: a intensidade dos CD's. Isso faz com que se apresentem insuficiências nos procedimentos de segmentação, devido essencialmente à presença de ruídos e à iluminação não uniforme na imagem, gerando “quebras” nas regiões das fronteiras. Os métodos mais comuns de segmentação por similaridade são caracterizados por algoritmos de limiarização (*thresholding*), crescimento de regiões (*region growing*) e divisão e fusão (*region spitting and merge*).

O método de limiarização discretiza objetos a partir da definição de limiares sobre o histograma da imagem. Onde, assume-se que a imagem limiarizada $g(x,y)$ receberá 0 (zero) para $f(x,y)$ (intensidade do contador digital) para valores menores que um limiar T e 1 (um) para $f(x,y)$ para valores maiores que o limiar T . Assim, a imagem $g(x,y)$ será constituída por regiões (valores igual a 1) e fundo (valores igual a 0). Analiticamente,

$f(x,y)$: imagem original

$g(x,y)$: imagem limiarizada

Se :

$f(x,y) < T$ então $g(x,y) = 0$

$f(x,y) \geq T$ então $g(x,y) = 1$

Quando o processo de limiarização envolve apenas uma função $f(x,y)$ tem-se um limiar global. Caso o processo envolva outra função (p.ex. média dos *pixels* adjacentes) tem-se um limiar dinâmico.

A Figura 8 apresenta o resultado de um processo de segmentação por limiarização utilizando uma imagem fotográfica monocromática. A Figura 8 A está indicando a imagem original com resolução radiométrica de 8 bits. A Figura 8 B apresenta o resultado da segmentação com limiar de 90 e a Figura 8 C com limiar de 165.



Figura 8 – Exemplo de segmentação pelo método de limiarização com uma imagem sintética obtida em <http://www.lenna.org> em dezembro de 2005

O método de crescimento de regiões trabalha a segmentação por descobertas de regiões através de agrupamento direto, de modo que, o procedimento agrupe *pixels* ou sub-regiões em regiões maiores. Partindo de *pixels* distribuídos o mais distante possível uns dos outros, *pixels* sementes, o algoritmo procura agregar demais *pixels* a estes, de forma que, iterativamente cada *pixel* semente forme uma região. A regra à agregação parte do cumprimento de determinadas propriedades (p.ex. intensidade, textura, etc.) que os *pixels* devem ter em relação ao *pixel* semente, limitados por um dado limiar e que estejam postos de modo adjacente ao *pixel* semente, ou em uma iteração seguinte, adjacentes à sub-região. O processo de crescimento de regiões encerra quando não houver mais possibilidade de agregação de *pixels* adicionais ou o *pixel* em consideração já pertença à outra região.

Estudos recentes de segmentação em imagens digitais apontam um novo indicativo de classificação quanto aos métodos de segmentação, onde duas linhas são apresentadas: métodos baseados no conhecimento (*top-down*) e métodos baseados nos dados (*bottom-up*). Ambos os métodos partem por dois componentes: o método de segmentação e os objetos que se deseja segmentar (objetos de interesse).

Os métodos de segmentação *top-down* se caracterizam pela definição prévia dos objetos de interesse e pela falta de definição quanto à forma de segmentação. Nestes métodos a estrutura de segmentação parte de operadores que consideram o modelo “*a priori*” dos objetos de interesse. O resultado da segmentação fornecerá, neste caso, somente os objetos que tiverem sido incorporados no modelo.

Os métodos *bottom-up* propõem uma segmentação geral, desconsiderando os objetos de interesse de modo que toda imagem seja segmentada. Neste caso, o método de segmentação normalmente utiliza dados estatísticos para particionar a imagem em regiões. Os principais métodos de segmentação utilizados, em se tratando de dados de sensoriamento remoto, são de característica *bottom-up*, pois todos os objetos de um conjunto de dados imagem são segmentados.

O método de segmentação ideal deveria produzir o número de segmentos igual ao número de objetos que uma cena apresentar. De um modo geral, todos os métodos de segmentação não produzem uma divisão perfeita da cena. Normalmente são gerados segmentos indesejados no processo, produzidos por insuficiência do método ou pela complexibilidade dos padrões e objetos reais de uma cena.

Quando o método de segmentação gerar uma quantidade de segmentos muito menor que a cena apresenta, aumentando significativamente o número total de objetos, diz-se que o processo de segmentação apresenta *over-segmentation*. Quando o método de segmentação produzir segmentos com uma dimensão muito maior que a dimensão real, combinando alguns objetos reais num único segmento, diminuindo o número total de objetos, diz-se que a segmentação apresenta *under-segmentation*.

A elipse em destaque no tom vermelho na Figura 9 apresenta, sobre os dados imagem do sistema *Quickbird*, objetos de diversas classes sobre um mesmo segmento, apresentando assim uma região com *under-segmentation*. A proposta correta seria a existência de vários segmentos estruturados sobre cada objeto.




Figura 9 – Exemplo de *under-segmentation* sobre dados imagem do sistema *Quickbird*

A Figura 10 apresenta sobre os mesmos dados imagem da Figura 9 outro resultado de segmentação com um número representativo de *over-segmentation*. Pode-se ver a presença de *over-segmentations* sobre toda a cena, visualizando sobre elementos de uma mesma classe diversos segmentos.




Figura 10 – Exemplo de *over-segmentation* sobre dados imagem do sistema *Quickbird*

Uma desvantagem que o método *top-down* apresentam em relação ao *bottom-up* diz respeito à forma de particionamento das regiões, que tendem a gerar um número grande de *over-segmentation*, devido a uma propriedade que estipula a utilização de um número fixo de sub-regiões no processo de divisão dos objetos, mesmo sobre objetos de forma e natureza distintas.

Muitos são os métodos de segmentação *top-down* e *bottom-up*, porém poucos processos fornecem informações adequadas para a classificação de imagens digitais, devido à variabilidade da natureza da imagem e das características dos métodos. TABB & AHUJA (1997) mostram a insuficiência de alguns métodos de segmentação, quando o objetivo tange a constituições de padrões espaciais, devido à

desconsideração dos métodos de segmentação sobre o parâmetro de escala, tais como, os métodos de limiarização, crescimento de regiões, divisão-fusão e watershed. BAATZ & SCHAPE (1999) apresentam as características da segmentação multiresolução e as propostas para seu uso. MOIGNE & TILTON (1995) apresentam as propriedades da segmentação, com métodos *bottom-up*, utilizando uma integração dos métodos de similaridade, descontinuidades e crescimento de regiões e MUELLER *et al.* (1997) aplicaram a segmentação com métodos *top-down* objetivando a caracterização das edificações de grande porte a partir de dados de sensores remotos de alta resolução espacial.

Em imagens de alta resolução espacial, os métodos com base em uma única característica da imagem não têm se mostrado eficientes em extrair as regiões de interesse. O método de segmentação multiresolução tem se apresentado apropriado a esta proposta, pois levam em consideração múltiplas características no processo de segmentação, assim a utilização dos objetos no processo de classificação partirá da segmentação prévia dos dados imagem por este método.

3.1.2. Segmentação Baseada em Objetos (Multiresolução)

A segmentação multiresolução pode ser descrita como uma técnica *bottom-up* de fusão de regiões, que leva em consideração múltiplas característica da imagem e que utiliza um algoritmo baseado em crescimento de regiões. (BAATZ & SCHAPE, 2000)

O processo de segmentação inicia-se considerando cada *pixel* como um objeto. Iterativamente um par de objetos é agrupado em um objeto de dimensão maior. A regra para o agrupamento (fusão) é baseada em um critério de heterogeneidade, que descreve a dissimilaridade de objetos adjacentes. O critério de heterogeneidade é uma combinação de propriedades espectrais e espaciais. O algoritmo descreve estas propriedades como critérios de cor (espectrais) e de forma (espaciais). O critério de

forma ainda é subdividido entre os parâmetros de compacidade e suavidade. Estes critérios podem ser traduzidos como uma ponderação em que a segmentação buscará priorizar na formação dos objetos.

Considerando um objeto arbitrário A , adjacente a outros n objetos, o par de objetos que apresentar o menor crescimento no critério de heterogeneidade é agrupado, em outras palavras, será agrupado o par de objetos que apresentar a maior similaridade. O processo termina quando o menor crescimento possível de um par de objetos excederem certo limiar, o parâmetro de escala. Um maior parâmetro de escala permitirá um número maior de iterações e agrupamentos, conseqüentemente resultará em objetos com maior dimensão.

Os principais componentes da segmentação multiresolução, conforme BAATZ & SCHAPE (2000), são:

- Decisão heurística para determinar os objetos que serão agrupados em cada etapa;
- Definição do critério de heterogeneidade de um par de objetos.

a) Decisão Heurística

A decisão heurística no processo de segmentação multiresolução cumpre o papel de encontrar os objetos que serão agrupados em cada iteração.

Sendo A um objeto qualquer, várias abordagens heurísticas podem ser aplicadas para encontrar um objeto adjacente B para o agrupamento, de um total de n objetos adjacentes.

O algoritmo disponível no software *eCognition* dispõe de quatro abordagens:

- **Ajustamento:** agrupa-se o objeto A com qualquer objeto vizinho B quando um critério de heterogeneidade é atingido.

- **Ajustamento ótimo:** agrupa-se o objeto A com qualquer objeto vizinho B quando o melhor critério de heterogeneidade é atingido. Melhor, refere-se ao menor crescimento possível da heterogeneidade entre A e um de seus n objetos vizinhos, respeitando o limiar do parâmetro de escala.
- **Ajustamento ótimo mútuo local:** agrupa-se o objeto A com qualquer objeto vizinho B quando o melhor critério de heterogeneidade é atingido, considerando que o objeto B atinja também o melhor critério de heterogeneidade para com o seu objeto C , de modo que o critério de heterogeneidade seja mútuo entre A e C .
- **Ajustamento ótimo mútuo global:** agrupa-se o par de objetos adjacente que atingir o melhor critério de heterogeneidade para a cena inteira.

b) Critério de Heterogeneidade

Sendo X um domínio espacial de n -dimensões, onde cada dimensão é representada por uma variável espectral ou espacial, dois objetos A e B serão similares, quanto mais próximos um do outro estiverem considerando todas as n -dimensões do domínio X .

Para uma dada dimensão d , a heterogeneidade espectral h entre um par de objetos A e B , pode ser medido por:

$$h = \sqrt{\sum_d (f_{Ad} - f_{Bd})} \quad (13)$$

Onde:

h : heterogeneidade

f_{Ad} : critério de agrupamento do objeto A na dimensão d

f_{Bd} : critério de agrupamento do objeto B na dimensão d

A equação (13) pode ser representada de modo padronizado, através do desvio-padrão sobre todos os segmentos da variável em cada dimensão σ_{fd} .

$$h = \sqrt{\sum_d \left(\frac{f_{Ad} - f_{Bd}}{\sigma_{fd}} \right)^2} \quad (14)$$

O critério de agrupamento f é definido com base na heterogeneidade espectral e espacial,

$$f = w \cdot h_{color} + (1 - w) \cdot h_{shape} \quad (15)$$

Onde:

w : peso dado à heterogeneidade espectral

h_{color} : heterogeneidade espectral

h_{shape} : heterogeneidade espacial

A heterogeneidade espectral (h_{color}) é dada por:

$$h_{color} = \sum_c w_c \left(n_{AB} \cdot \sigma_c^{AB} - (n_A \cdot \sigma_c^A + n_B \cdot \sigma_c^B) \right) \quad (16)$$

Onde:

c : variável no domínio espacial

w_c : peso dado à heterogeneidade espectral na dimensão c

n_{AB} : tamanho do objeto agrupado AB

σ^{AB} : desvio-padrão do objeto agrupado AB

n_A : tamanho do objeto A

σ^A : desvio-padrão do objeto A

n_B : tamanho do objeto B

σ^B : desvio-padrão do B

A heterogeneidade espacial (h_{shape}) é dada por:

$$h_{shape} = w_{cmpct} \cdot h_{cmpct} + (1 - w_{cmpct}) \cdot h_{smooth} \quad (17)$$

Onde:

w_{cmpct} : peso dado a compacidade

h_{cmpct} : compacidade

h_{smooth} : suavidade

O parâmetro de compacidade (h_{smooth}) descreve a concentração de informações (*pixels*) sobre um objeto conforme o preenchimento de *pixels* sobre um retângulo inscrito ao segmento. Este parâmetro pode ser também entendido como a compactação do objeto.

$$h_{cmpct} = n_{AB} \cdot \frac{l_{AB}}{b_{AB}} - \left(n_A \cdot \frac{l_A}{b_A} + n_B \cdot \frac{l_B}{b_B} \right) \quad (18)$$

Onde:

n_{AB} : tamanho do objeto agrupado AB

l_{AB} : perímetro do objeto agrupado AB

b_{AB} : perímetro do retângulo inscrito ao objeto agrupado AB

- n_A : tamanho do objeto A
 l_A : perímetro do objeto A
 b_A : perímetro do retângulo inscrito ao objeto A
 n_B : tamanho do objeto B
 l_B : perímetro do objeto B
 b_B : perímetro do retângulo inscrito ao objeto B

O parâmetro de suavidade (h_{smooth}) descreve a fragmentação dos limites das bordas do objeto, quanto menor a suavidade, maior a irregularidade, mais fractal.

$$h_{smooth} = n_{AB} \cdot \frac{l_{AB}}{\sqrt{n_{AB}}} - \left(n_A \cdot \frac{l_A}{\sqrt{n_A}} + n_B \cdot \frac{l_B}{\sqrt{n_B}} \right) \quad (19)$$

Onde:

- n_{AB} : tamanho do objeto agrupado AB
 l_{AB} : perímetro do objeto agrupado AB
 n_A : tamanho do objeto A
 l_A : perímetro do objeto A
 n_B : tamanho do objeto B
 l_B : perímetro do objeto B

Ao agrupar um par de objetos, mesmo ao considerar a suposição da menor dimensão possível dos objetos, como é o caso de um par de *pixels*, a composição da heterogeneidade média do novo objeto formado será maior que a dos objetos originais.

O principal objetivo para o procedimento de agrupamento, visa obter o menor crescimento possível da heterogeneidade em cada iteração (critério de heterogeneidade). Há diferentes modos de descrever essa mudança de heterogeneidade (h_{diff}) antes e depois do agrupamento:

$$h_{diff} = h_{AB} - \frac{h_A + h_B}{2} \quad (20)$$

Onde:

h_{AB} : heterogeneidade do objeto agrupado AB

h_A : heterogeneidade do objeto A

h_B : heterogeneidade do objeto B

Outro modo faz de descrever essa mudança é considerar que a heterogeneidade média dos objetos de tamanho n precisa ser minimizada,

$$h_{diff} = h_{AB} - \frac{h_A \cdot n_A + h_B \cdot n_B}{n_A + n_B} \quad (21)$$

Onde:

h_{AB} : heterogeneidade do objeto agrupado AB

h_A : heterogeneidade do objeto A

n_A : tamanho do objeto A

h_B : heterogeneidade do objeto B

n_B : tamanho do objeto B

Ou ainda, ponderar a heterogeneidade dos objetos pelo seu tamanho,

$$h_{diff} = \sum_c w_c (n_A (h_{ABc} - h_{Ac}) + n_B (h_{ABc} - h_{Bc})) \quad (22)$$

3.2. ATRIBUTOS PARA CARACTERIZAÇÃO DOS OBJETOS

O estabelecimento de padrões para caracterização dos objetos partiu de estudos do modo cognitivo de ação pelo nosso cérebro. Conforme explica VENDRIG (1997) o modo de percepção visual parte da ação das células nervosas na retina, que agem separando as imagens em componentes, como contornos, cores, texturas, informações contextuais e temporais. Estes fragmentos de informações são reunidos no cérebro em uma única imagem, de onde a informação sobre seus conteúdos é extraída.

Pela natureza exclusiva que cada componente apresenta, qualquer fragmento de informação pode ser definido e quantificado. Sua qualificação denomina-se de atributo, assim, pode-se definir que atributo é a designação de uma variável categorizada por uma característica cognitiva própria associada a uma classe ou um elemento de representação. Os atributos mais convencionais quando se tratando de informações de sensoriamento remoto, são os espectrais, de contexto e os espaciais de forma e de textura.

Os atributos que possuem a mesma natureza de formação, como por exemplo, um conjunto de atributos espectrais, não necessariamente estará representando um determinado padrão de modo uniforme. Cada elemento representante do atributo, ou seja, cada variável, também chamado na literatura de descritor, estará fornecendo um formato distinto de resposta. Assim, um atributo é decomposto por variáveis, desenhadas conforme uma ou mais características comuns. Com isso, pode-se inferir que uma configuração de atributos e variáveis estruturadas e quantificadas pode descrever e representar com confiança um conjunto de dados.

Ao analisar uma imagem digital colorida em cor verdadeira, podemos facilmente inferir a existência de três variáveis de natureza espectral, cada uma sobre determinada faixa de comprimento de onda, comumente sobre as faixas do visível: vermelho, verde e azul. Deste modo cada alvo da imagem terá uma quantificação diferente para cada variável, ou seja, apresentará diferentes contadores digitais para cada uma destas bandas. Essa proposição se estende aos demais atributos, podendo representar, por exemplo, sobre os atributos espaciais, variáveis de área, perímetro, assimetria, etc.

Nessa dissertação será utilizada a denominação variável, ao invés de descritor, por uma convenção das ciências estatísticas.

Em se tratando de dados em sensores remotos a informação imediata que é fornecida envolve essencialmente elementos espectrais, porém essa não é a única informação que pode ser extraída destes dados. A literatura cita inúmeras propostas para modelagem e utilização de atributos adicionais aos espectrais. MELGANI (2006) combinou a utilização de atributos contextuais e temporais para reconstituição espectral por incidência de nuvens sobre as imagens de sensoriamento remoto. DELLAPOS & GAMBA (2003) apresentaram um proposta para classificação de áreas urbanas utilizando dados de textura. RYHERD & WOODCOCK (1996) utilizou a combinação de atributos espectrais e de textura para segmentação de imagens de sensoriamento remoto. ZHANG & LU (2004) pesquisaram a descrição e representação de atributos espaciais de forma. WESZKA *et al.* (1976) propuseram a utilização de atributos de textura no processo classificação.

Para poder exemplificar visualmente as variáveis espectrais e espaciais em dados de sensoriamento remoto, representou-se, através da Figura 11, uma cena original do sistema *Quickbird*. Nesta figura são representados os objetos do ambiente urbano, essencialmente: vias (asfalto), edificação (telhado de cerâmica, zinco e amianto) e vegetação arbórea. A Figura 12, a Figura 13 e a Figura 14 representam as variáveis obtidas a partir destes dados imagem.



Figura 11 – Exemplo de dados imagem do sistema *Quickbird* com representação do ambiente urbano

A Figura 12 está representando o atributo espectral da Figura 11, formado pela variável brilho quantizada em 8 bits.

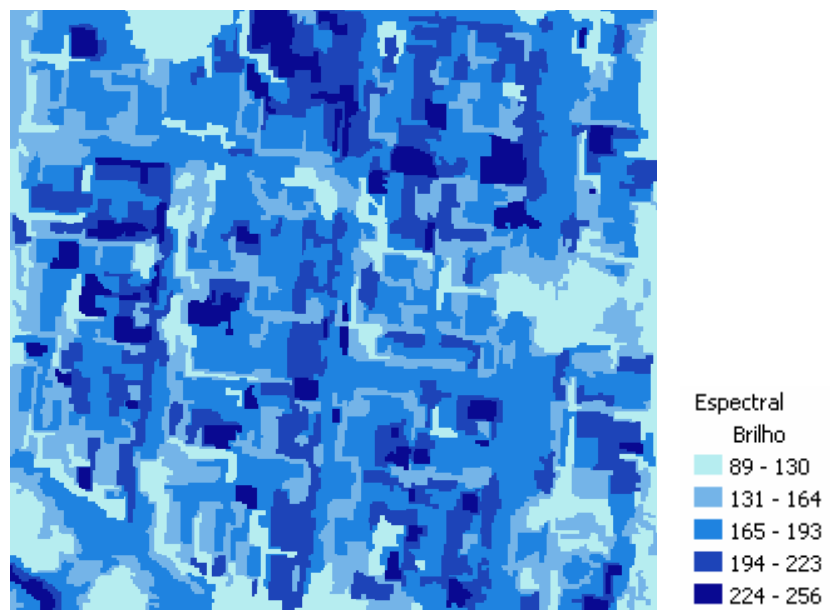


Figura 12 – Representação do atributo espectral da variável brilho sobre os dados imagem apresentados pela Figura 11

A Figura 13 está representando o atributo espacial de geometria da Figura 11, formado pela variável área, em unidade m^2 .

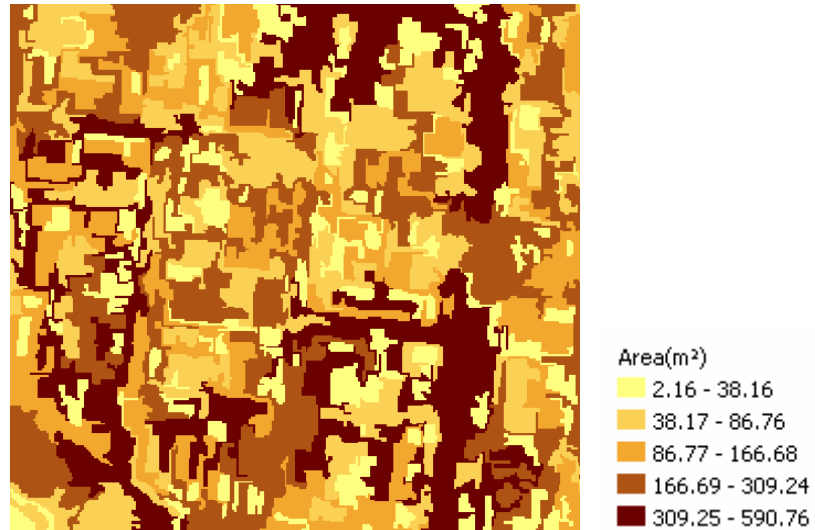


Figura 13 – Representação do atributo espacial (geometria) da variável área sobre os dados imagem apresentados pela Figura 11

A Figura 14 está representando o atributo espacial de textura da Figura 11, formado pela variável homogeneidade.




Figura 14 – Representação do atributo espacial (textura) da variável homogeneidade sobre os dados imagem apresentados pela Figura 11

O ganho com a adição de atributos no desenvolvimento de estudos de processamento de imagens e reconhecimentos de padrões pode significar a solução de problemas traçados como insolúveis ou com soluções incompletas ou insuficientes. Porém, a perfeita definição dos atributos que caracterizam os elementos do mundo real ainda continuam a ser submetidos a rígidas pesquisas, frente à infinda possibilidade de combinação de formatos de dados de diferentes equipamentos sensoriais aos mais distintos padrões de objetos que espaço real pode apresentar.

Alguns dos métodos mais empregados atualmente encontram-se disponíveis na forma de algoritmos e softwares. Como a presente proposta visa à utilização combinada de atributos espaciais de forma e textura, além dos espectrais, num processo de classificação hierárquico, buscando determinar parâmetros que quantifiquem a eficiência individual e/ou conjunta das variáveis de atributos no processo de classificação para cada classe, a importância para delineamento das variáveis recebe um destaque especial. A presente dissertação fará uso de um software comercial (*eCognition*) para fins de segmentação da imagem e estimação dos atributos espaciais relativos à forma e textura além dos de natureza puramente espectral. O classificador adotado nesta dissertação foi programado em ambiente *MATLAB*.

3.2.1. Atributos Espectrais

Os atributos espectrais dizem respeito a radiância refletida e/ou emitida pelos objetos de interesse nas diversas regiões do espectro eletromagnético abrangidas pelos dados. Este atributo define o comportamento espectral de cada objeto em particular. As variáveis espectrais utilizadas nesta dissertação são:

- Média Espectral - Banda 1 (0.45 a 0.52 μm);
- Desvio-padrão Espectral - Banda 1 (0.45 a 0.52 μm);

- Razão Espectral - Banda 1 (0.45 a 0.52 μm);
- Média Espectral - Banda 2 (0.52 a 0.60 μm);
- Desvio-padrão Espectral - Banda 2 (0.52 a 0.60 μm);
- Razão Espectral - Banda 2 (0.52 a 0.60 μm);
- Média Espectral - Banda 3 (0.60 a 0.69 μm);
- Desvio-padrão Espectral - Banda 3 (0.60 a 0.69 μm);
- Razão Espectral - Banda 3 (0.60 a 0.69 μm);
- Média Espectral - Banda 4 (0.76 a 0.90 μm);
- Desvio-padrão Espectral - Banda 4 (0.76 a 0.90 μm);
- Razão Espectral - Banda 4 (0.76 a 0.90 μm);
- Brilho;
- Diferença Máxima.

Média Espectral: A variável espectral média expressa o valor médio dos contadores digitais de uma banda espectral para cada objeto da imagem segmentada.

$$\bar{c}_L = \frac{1}{n} \cdot \sum_{i=1}^n c_{Li} \quad (23)$$

Onde:

\bar{c}_L : média espectral do segmento na banda L

n : número de *pixels* de um segmento

c_{Li} : valor do contador digital do *pixel* "i" na banda L

Desvio-padrão Espectral: A variável espectral desvio-padrão quantifica a variação dos contadores digitais para cada objeto em uma banda espectral na imagem segmentada.

$$\sigma_L = \sqrt{\frac{1}{n-1} \cdot \sum_{i=1}^n (c_{Li} - \bar{c}_L)^2} \quad (24)$$

Onde:

σ_L : desvio-padrão espectral do segmento

n : número de *pixels* de um segmento

c_{Li} : valor do contador digital do *pixel* "i" na banda L

\bar{c}_L : média espectral do segmento na banda L

Razão Espectral: A razão espectral é definida pela razão entre a média espectral do segmento de uma banda pelo somatório das médias espectrais sobre todos os segmentos.

$$r_L = \frac{\bar{c}_{L,obj}}{\sum_{j=1}^m c_{Lj}} \quad (25)$$

Onde:

r_L : razão espectral do segmento na banda L

$\bar{c}_{L,obj}$: média espectral do segmento na banda L

j : identificação do segmento

m : número total de segmentos da banda L

Brilho: A variável espectral brilho é a componente que carrega a informação espectral da totalidade de bandas espectrais.

$$b = \frac{1}{n_L} \cdot \sum_{i=1}^{n_L} \bar{c}_i \quad (26)$$

Onde:

b : brilho

n_L : número total de bandas espectrais

\bar{c}_i : média espectral do segmento "i"

Diferença Máxima: A variável espectral diferença máxima indica a máxima diferença espectral de um segmento entre todas as variáveis espectrais de média.

$$md = \frac{(\bar{c}_{i \text{ La,max}} - \bar{c}_{i \text{ Lb,min}})}{b} \quad (27)$$

Onde:

md : diferença máxima espectral

$\bar{c}_{i \text{ La,max}}$: máxima média espectral do segmento i na banda La

$\bar{c}_{i \text{ Lb,min}}$: mínima média espectral do segmento i na banda Lb

b : brilho

3.2.2. Atributos Espaciais

Os atributos espaciais estão relacionados às variáveis de forma, dimensão e textura, carregando informações relevantes no processo de entendimento de uma cena. O ser humano utiliza estes atributos de modo rotineiro no processo de entendimento do ambiente que o cerca. O desempenho dos métodos de classificação de imagens digitais pode, em princípio, beneficiar-se muito pela introdução de informações desta natureza.

A utilização dos atributos espaciais requer, entretanto, dados imagem com uma resolução espacial compatível com as grandezas a serem estimadas. Sistemas sensores com média resolução espacial, como por exemplo, o sistema *Landsat-TM*, geralmente não oferecem uma resolução espacial adequada à muitos estudos. Com a disponibilidade de novos sistemas, fornecendo dados imagem com resolução espacial da ordem do metro, o desenvolvimento de metodologias implementando atributos espaciais ao processo de classificação de imagens digitais adquiriu uma nova importância.

As variáveis espaciais normalmente utilizam uma unidade de medida diferente uma das outras por características individuais próprias. Por exemplo, uma variável de área utilizará uma unidade de medida diferente de uma variável que quantifica a assimetria dos objetos. A consequência disso é a necessidade de normalização das variáveis, de modo que haja uma escala comum entre todas as variáveis, permitindo a utilização conjunta de medidas de correlação estatística entre as classes. Essa quantização gera a perda da associação da unidade de medida natural da variável. Quando inicialmente tinha-se, por exemplo, para a variável área, a unidade metros quadrados, após a normalização tem-se um valor quantizado sobre a escala definida, conforme a resolução radiométrica, em contadores digitais. Porém, isso não gera qualquer prejuízo no processo de classificação, agindo apenas como um fator de escala. Essa proposição está deduzida analiticamente no Anexo 6.

Os atributos espaciais podem ser categorizados por suas características, comumente com propriedades geométricas e de textura. Os atributos espaciais de textura são os mais pesquisados atualmente, propostos para o emprego em diversas

faculdades do conhecimento, com aplicações em análises de padrões na medicina, indústria, artes e nas ciências em geral. CHICA-OLMO & ABARCA-HERNÁNDEZ (2000) pesquisaram a utilização de atributos de textura para classificação baseada em *pixel* em dados de sensoriamento remoto. MYINT & LAM (2005) avaliaram o ganho da utilização da textura para classificação do ambiente urbano em imagens de alta resolução espacial.

Diferentemente dos atributos espectrais, os atributos espaciais não são propriedades de *pixels* individuais, mas de regiões da imagem. Desta forma, a estimação de atributos espaciais requer uma prévia segmentação da imagem.

a) Atributos Geométricos

A caracterização matemática dos elementos do espaço e da variabilidade dos fenômenos físicos, por meio de regras e do dimensionamento da morfologia geométrica dos elementos representados numa cena, pode ser descrita como o principal objetivo das pesquisas referentes aos atributos geométricos.

Uma grande quantidade de pesquisas para extração dos atributos geométricos tem sido desenvolvida, CRESSIE (1990) apresentou a determinação de estruturas espaciais em dados de sensoriamento remoto, na caracterização dos elementos por abordagens estatísticas. BOOGAART (1999) investigou a análise e uso da dimensão fractal e OLSEN *et al.* (1993) a modelagem espacial utilizando análises empíricas e determinísticas.

Os atributos geométricos utilizados na caracterização de objetos em uma imagem digital são geralmente aqueles empregados na morfologia matemática, tal como, a área, o perímetro, a largura, etc. Para fins de utilização no processo de classificação, estes atributos devem ser invariantes frente transformações como translação, rotação e variações de escala.

Nesta dissertação são utilizadas as seguintes variáveis geométricas:

- *Area* (área);
- *Length* (comprimento);
- *Width* (largura);
- *Length/width* (razão comprimento por largura);
- *Compactness* (compactação);
- *Elliptic Fit* (ajuste elíptico);
- *Rectangular Fit* (ajuste retangular);
- *Border length* (comprimento da borda);
- *Shape index* (índice de forma);
- *Density* (densidade);
- *Main Direction* (direção principal);
- *Asimmetry* (assimetria);

Como serão apresentadas no Capítulo 4, algumas dessas variáveis não apresentam resultados satisfatórios, sendo por falta do cumprimento das regras supracitadas, como pela falta de comportamento gaussiano.

Área (Area): A variável espacial área pode ser vista como uma medida de quantidade de superfície, definida analiticamente sobre os segmentos de uma imagem, a partir da seguinte regra: um único *pixel* tem o valor absoluto de um (1) e uma única dimensão no espaço, derivado da sua resolução espacial.

$$A = a \cdot \sum_{i=1}^n i \quad (28)$$

Onde:

A : área

a : área verdadeira de um único *pixel*

n : número de *pixels* de um segmento

i : unidade de *pixel*

Razão Comprimento por Largura (*Length/Width*): A variável espacial razão comprimento por largura induz a informação da forma geométrica dos objetos, onde quanto mais próximo do valor um (1) mais regular é a objeto. Para determinação analítica da variável razão comprimento por largura propõem-se a utilização das componentes principais dos segmentos.

A fundamentação da análise de componentes principais está baseada na supressão de dados redundantes contidas nas variáveis com alta correlação linear, para uma ou mais componentes, concentrando um maior número de informações. Após a transformação da análise de componentes principais o conteúdo máximo de informação será concentrado na primeira componente principal, havendo decréscimo de informação nas componentes subseqüentes.

Por definição, pode-se inferir que ao colocar num gráfico bidimensional as variáveis espaciais de linha e coluna, de cada objeto, a direção que contiver a maior parte da informação será a primeira componente (*CP1*), em outras palavras, a *CP1* é aquela que passa pelo eixo central da distribuição espacial. A segunda componente (*CP2*) será composta pela direção que contiver a segunda maior parcela de informações e será perpendicular a primeira componente, logo,

$$CP1 = f(\text{linha}, \text{coluna})$$

$$CP2 = f(\text{linha}, \text{coluna})$$

Os autovetores vão fornecer a direção destas componentes, enquanto que os autovalores, a quantidade de informação original que foi comprimida nesta componente.

A determinação da variável razão comprimento por largura, se dará pela subtração dos valores mínimos e máximos da primeira componente, que estará representando o comprimento do objeto e da mesma operação com valores mínimos e máximos da segunda componente, que representará a largura.

$$\gamma = \frac{eig_1(S)}{eig_2(S)} \quad (29)$$

Onde:

γ : razão comprimento por largura

$eig_1(S)$: autovalor da primeira componente do segmento “S”

$eig_2(S)$: autovalor da segunda componente do segmento “S”

Comprimento (*Length*): A variável comprimento pode ser definida pela a extensão linear no espaço de uma extremidade à outra em um objeto. A proposta para o cálculo do comprimento parte da utilização da variável espacial razão comprimento por largura. Ao propor um retângulo inscrito a um objeto verifica-se que as dimensões de comprimento e largura do objeto e do retângulo são iguais. Assim, para determinar o comprimento de um objeto pode-se utilizar a área do retângulo inscrito ao segmento (*Ap*). A Figura 15 apresenta uma suposição das dimensões de um objeto qualquer, apresentado pela cor azul sobre a matriz de *pixels* e um retângulo envolvente.

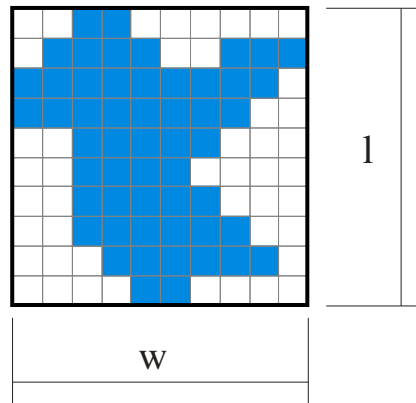


Figura 15 – Parâmetros qualitativos dos objetos para formação da variável espacial comprimento

Verifica-se pela Figura 15 que a área do retângulo pode ser dada pelo produto comprimento (l) por largura (w), assim:

$$Ap = l \cdot w \quad (30)$$

Isolando l , tem-se:

$$l = \frac{Ap}{w} \quad (31)$$

O resultado não será alterado se multiplicar a equação (31) pelo comprimento.

$$l^2 = Ap \cdot \left(\frac{l}{w} \right) \quad (32)$$

A expressão para determinação da variável espacial comprimento, fica:

$$l = \sqrt{Ap \cdot \gamma} \quad (33)$$

Onde:

l : comprimento

A_p : área do retângulo inscrito ao objeto

γ : razão comprimento por largura

Largura (*Width*): A variável espacial largura pode ser definida pela a extensão linear no espaço de um lado ao outro em um objeto. A proposta para o cálculo da largura parte da mesma proposição para a determinação do comprimento.

$$w = \sqrt{\frac{A_p}{\gamma}} \quad (34)$$

Onde:

w : largura

A_p : área do retângulo inscrito ao objeto

γ : razão comprimento por largura

Compactação (*Compactness*): A variável espacial compactação representa um índice de concentração de informações (*pixels*) sobre um segmento, mensurando o preenchimento de *pixels* sobre um retângulo inscrito num segmento.

$$c = \frac{(l \cdot w)}{n} \quad (35)$$

Onde:

c : compactação

w : largura

l : comprimento

n : número de *pixels* de um segmento

Ajuste Elíptico (*Elliptic Fit*): A variável espacial ajuste elíptico representa uma aproximação do objeto em relação à forma geométrica da elipse. A definição desta variável parte da determinação de uma elipse inscrita, exinscrita ou circunscrita sobre o segmento, de modo que, as áreas do objeto e da elipse sejam iguais.

$$ef = \frac{Aef_{out}}{Aef_{in}} \quad (36)$$

Onde:

ef : ajuste elíptico

Aef_{out} : área da elipse que o segmento não está contido

Aef_{in} : área da elipse que o segmento está contido

Ajuste Retangular (*Rectangular Fit*): A variável espacial ajuste retangular segue a mesma proposta que o ajuste elíptico, porém com uma aproximação do objeto em relação à forma geométrica retangular.

$$rf = \frac{Arf_{out}}{Arf_{in}} \quad (37)$$

Onde:

rf : ajuste retangular

Arf_{out} : área do retângulo que o segmento não está contido

Arf_{in} : área do retângulo que o segmento está contido

Comprimento da Borda (*Border length*): A variável espacial comprimento da borda, também chamado de perímetro, pode ser definida pela extensão linear no

espaço do contorno de um objeto. Se utilizar a dimensão real do *pixel* no espaço, segundo a resolução espacial, tem-se o comprimento da borda verdadeira para o segmento.

$$bl = \sum_{ib=1}^n ib \quad (38)$$

Onde:

bl : comprimento da borda

ib : unidade de *pixel* da borda do segmento ou da borda da imagem

n : número de *pixels* de um segmento

Índice de Forma (*Shape Index*): A variável espacial índice de forma refere-se a um índice que fornece a informação de suavidade e rugosidade dos contornos de um objeto. Quanto menor for o índice de forma, mais suave será o contorno e quanto maior for o índice de forma, mais rugoso, ou seja, mais fractal, mais irregular, ele será.

$$s = \frac{bl}{4 \cdot \sqrt{A}} \quad (39)$$

Onde:

s : índice de forma

bl : comprimento da borda

A : área

Densidade (*Density*): A variável espacial densidade descreve a compactação dos objetos. A morfologia de um segmento com a compactação ideal está o mais próximo possível de um quadrado. Quanto mais similar o segmento for da figura

geométrica do quadrado, maior densidade ele terá e quanto mais distinto o segmento for de um quadrado, menor densidade ele terá.

$$d = \frac{\sqrt{n}}{1 + \sqrt{\text{var}(X) + \text{var}(Y)}} \quad (40)$$

Onde:

d : densidade

n : número de *pixels* de um segmento

$\text{var}(X)$: componente na direção de X

$\text{var}(Y)$: componente na direção de Y

Direção Principal (*Main Direction*): A variável espacial direção principal indica a orientação espacial mais significativa para cada objeto. A proposta para definição desta variável segue da utilização do autovetor da primeira componente principal. Deste modo, a direção principal de um segmento é o próprio autovetor da primeira componente deste segmento, em unidades de medida de graus, variando de 0 a 180°.

$$md = eig_1(S) \quad (41)$$

Onde:

md : direção principal

$eig_1(S)$: autovetor da primeira componente do segmento “ S ”

Assimetria (*Assimetry*): A variável espacial assimetria representa a regularidade geométrica de um segmento. O segmento que for morfologicamente mais próximo à circunferência e o quadrado terão menor valor de assimetria, ou seja, mais simétrico será.

$$k = 1 - \frac{l}{w} \quad (42)$$

Onde:

k : assimetria

l : comprimento

w : largura

b) Textura

A textura de uma região da imagem é visualmente interpretada por uma repetição tonal de *pixels* nesta região. A textura é definida como uma combinação entre a magnitude e a frequência da variação tonal numa imagem, produzida pelo efeito conjunto de todos os padrões, no espaço na imagem. A tonalidade e a textura, apesar de poder ser considerada como propriedades independentes, possuem alta correlação. Pois, se não houvessem variações na tonalidade, não haveria percepção quanto a mudança da textura (GONZALEZ & WOODS,1993).

Diferentemente dos demais atributos, que descrevem as propriedades espectrais ou a estrutura dos objetos, a textura contém informações sobre a distribuição espacial das variações espectrais dos objetos. Adicionalmente, essas variações espectrais podem ser consideradas como uma função de escala onde o objeto é observado.

HARALICK (1979) coloca que a textura pode ser descrita pela quantidade de padrões primitivos, sua forma e organização espacial. Assim, a suposição mais conveniente para caracterizar a textura parte da premissa que é preciso caracterizar a propriedade tonal dos padrões primitivos e a suas inter-relações espaciais. Muitos algoritmos ao longo dos anos foram propostos para tal fim. Os algoritmos de processamento de textura são geralmente divididos em estruturais e estatísticos.

Algumas propostas subdividem ainda mais estas categorias, incluindo à estes também o método chamado de espectral (CHICA-OLMO & ABARCA-HERNÁNDEZ, 2000).

Os métodos chamados estruturais consideram a textura com uma repetição de padrões primitivos básicos, definidas através de regras específicas (HE *et al.*, 1987).

As propostas mais usuais para definição e extração de atributos de textura são os métodos estatísticos. Os métodos estatísticos propõem-se a modelar a textura com base na distribuição dos contadores digitais. Inúmeras propostas para definição dos atributos de textura estão apresentados na literatura. SALI & WOLFSON (1992) descreveram os principais métodos estatísticos para representação de atributos de textura, a partir de estatísticas de primeira ordem, onde são calculadas variáveis de média, variância e de momento, em relação à vizinhança de um *pixel*; estatísticas de segunda ordem, que estão relacionadas à utilização da matriz de coocorrência dos CD's; convolução da imagem, por meio de filtragem espacial com uso de máscaras para discriminação da textura; transformada de Fourier, que caracteriza textura em termos de frequências espaciais; e por fractais, onde a proposta fundamental da teoria dos fractais é de caracterizar a ocorrência de irregularidades em todos os níveis de resolução, de modo que discretize graus dessa irregularidade, descrevendo assim, as mudanças dos padrões de textura (DAWSON & PARSONS, 1994).

Esta dissertação definirá os atributos espaciais de textura pela utilização de estatísticas de segunda ordem, estimadas a partir das matrizes de coocorrência dos níveis de cinza (*Grey Level Cooccurrence Matrix*) (GLCM). Enquanto que as medidas de primeira ordem descrevem a distribuição dos níveis de cinza de uma região da imagem, as medidas de segunda ordem, além de descreverem a distribuição, apresentam a relação espacial entre os *pixels*.

Proposta originalmente por HARALICK (1979), a matriz de coocorrência faz uso da frequência relativa P_{ij} , com que um *pixel* com CD i e outro com CD j ocorrem na imagem, separados por uma determinada distância em uma dada direção.

Sendo uma imagem retangular I , com N_x *pixels* na direção horizontal e N_y *pixels* na direção vertical, sendo discretizada com N_g níveis de cinza. Denomina-se $L_x=\{1,2,\dots, N_x\}$ o domínio espacial horizontal e $L_y=\{1,2,\dots, N_y\}$ o domínio espacial vertical e $G=\{1,2,\dots, N_g\}$ o conjunto de N_g contadores digitais quantizados.

P_{ij} é uma matriz com dimensão $N_g \times N_g$, cujos elementos representam à frequência de ocorrência dos CD (i,j) na imagem I , separados por um vetor (x,y) . Matematicamente,

$$P_{i,j} = \# \{ [(k,l), (m,n)] \in [(N_x \times N_y) \times (N_x \times N_y)] \mid \quad (43)$$

$$[(I(k,l) = i) \wedge (I(m,n) = j)] \wedge [(m - k = x) \wedge (n - l = y)] \}$$

Como as GLCM são dependentes da frequência de ocorrência, elas são simétricas e devem possuir uma função que indique a relação angular (θ) e a relação de distância (d) entre um par de CDs. Assim, devem existir diferentes GLCM, conforme a orientação de cada relação angular θ e relação de distância (d).

No que diz respeito aos relacionamentos angulares, são possíveis utilizar quatro relacionamentos diferentes (0° , 45° , 90° , 135°). O ângulo de 0° representa a direção vertical e o ângulo de 90° representa a direção horizontal, o ângulo de 45° a direção entre o primeiro e o terceiro quadrante, enquanto que o de 135° no segundo e quarto quadrante. A Figura 16 apresenta a convenção utilizada nesta dissertação da orientação aos relacionamentos angulares sobre uma matriz sintética.




Figura 16 – Orientação aos relacionamentos angulares da GLCM

Para realizar a GLCM invariante à direção utiliza-se a soma de frequência dos CDs em todas as direções, ou seja, a soma de quatro GLCM (0°, 45°, 90°, 135°).

De um modo geral, utiliza-se a matriz normalizada para calcular a frequência relativa, conforme a expressão (44).

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}} \quad (44)$$

Onde:

$P_{i,j}$: valor normalizado do CD para os *pixels* i e j

$V_{i,j}$: valor do *pixel* da imagem na posição i,j

N : número de linhas ou de colunas

Supondo uma imagem representada pelos contadores digitais apresentados pela Figura 17, a GLCM dessa imagem, disposta pela da orientação angular de 90°, indicará a frequência de ocorrência dos CDs na direção horizontal, nos sentidos da esquerda para a direita e da direita para esquerda. A GLCM com distância horizontal de 1 *pixel*, está apresentada na Figura 18.

1	3	3	4	7
1	1	0	2	1
4	4	1	7	1
3	3	2	4	3
4	4	7	7	4

Figura 17 – Representação sintética dos contadores digitais de uma imagem digital

	1	2	3	4	7
1	2	1	1	1	1
2	1	0	1	1	0
3	1	1	4	2	0
4	1	1	2	4	3
7	1	0	0	3	2

Figura 18 – Representação da matriz de coocorrência dos contadores digitais na direção horizontal (90°) da Figura 17

As linhas e colunas em negrito da Figura 18, dizem respeito aos CD's apresentados na Figura 17, de modo que, cada CD da GLCM indique a frequência de ocorrência dos relativos CD na imagem original. Se, por exemplo, estivessem representados 8 CD's diferentes sobre a Figura 17, a dimensão da GLCM da Figura 18 seria 8x8. Assim, dimensão da GLCM não está associada ao tamanho real da imagem, e sim à quantidade de variações dos CD's da imagem.

Cada elemento da GLCM indica a incidência dos CD's i e j na direção suposta. Na Figura 18, o elemento em destaque pela cor amarela, indica a existência de duas células vizinhas, na orientação horizontal (90°), no sentido da esquerda para direita e da direita para a esquerda, com os CD's iguais a 1. Estes elementos também estão em destaque na Figura 18, pela mesma cor amarela.

Os elementos em destaque pela cor verde na Figura 18 indicam a incidência uma (1) ocorrência dos CD's 1 e 4 na orientação horizontal (90°), no sentido da direita para a esquerda. Os elementos em destaque pela cor verde da Figura 17 apresentam a posição desta ocorrência.

HARALICK (1973) sugere um conjunto variáveis que podem ser utilizadas para descrever a textura a partir da matriz de covariância, dentre elas pode-se citar:

homogeneidade, contraste, entropia, desvio-padrão, segundo momento angular, correlação, dispersão, concentração, etc.

A eficiência das variáveis de homogeneidade, contraste, dissimilaridade, entropia, média, desvio-padrão e correlação, partindo dos CD's individuais para cada segmento, foram quantificados e pesquisados nesta dissertação.

Homogeneidade (*Homogeneity*): A variável espacial de homogeneidade descreve uma medida da homogeneidade local dos níveis de cinza em uma imagem. A quantificação da medida da homogeneidade receberá os maiores valores para as menores diferenças entre os CD's.

$$h = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1+(i-j)^2} \quad (45)$$

Onde:

h : homogeneidade

i : identificação da linha

j : identificação da coluna

$P_{i,j}$: valor normalizado do CD para os *pixels* i e j

N : número de linhas ou de colunas

Contraste (*Contrast*): A variável contraste diz respeito à diferença entre os mais altos e os mais baixos valores de um conjunto de *pixels* adjacentes (frequência espacial).

$$c = \sum_{i,j=0}^{N-1} P_{i,j} (i-j)^2 \quad (46)$$

Onde:

c : contraste

i : identificação da linha

j : identificação da coluna

$P_{i,j}$: valor normalizado do CD para os *pixels* i e j

N : número de linhas ou de colunas

Dissimilaridade (*Dissimilarity*): A variável dissimilaridade quantifica a diferença interna entre os elementos. Quanto maior for a diferença entre os elementos, maior será o valor da dissimilaridade. A dissimilaridade é muito semelhante ao contraste, porém apresentada com maior amplitude.

$$d = \sum_{i,j=0}^{N-1} P_{i,j} |i - j| \quad (47)$$

Onde:

d : dissimilaridade

i : identificação da linha

j : identificação da coluna

$P_{i,j}$: valor normalizado do CD para os *pixels* i e j

N : número de linhas ou de colunas

Entropia (*Entropy*): A variável entropia estima a desordem dos dados. A entropia está relacionada à energia da GLCM através de uma correlação linear negativa.

Menores valores apresentados pela GLCM indicam que menos uniforme será a textura e maior o grau de desordem (entropia).

$$e = \sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j}) \quad (48)$$

Onde:

e : entropia

$P_{i,j}$: valor normalizado do CD para os *pixels* i e j

N : número de linhas ou de colunas

Momento Angular de Segunda Ordem (*Angular Second Moment*): O momento angular de segunda ordem avalia a uniformidade da textura, segundo a repetição de pares de CDs. Quando um objeto é homogêneo, apenas os *pixels* com CD's muito similares estão presentes e quando a textura é uniforme, poucos elementos da GLCM são diferentes de zero, deste modo a energia alcança valores próximos ao valor máximo. Os maiores valores de energia ocorrem quando a distribuição dos CD's é periódica ou constante.

$$asm = \sum_{i,j=0}^{N-1} P_{i,j}^2 \quad (49)$$

Onde:

asm : momento angular de segunda ordem

$P_{i,j}$: valor normalizado do CD para os *pixels* i e j

N : número de linhas ou de colunas

Como, em dados de sensoriamento remoto, com alta resolução espacial, em especial compreendendo o espaço urbano, a quantidade de padrões de distribuição periódica ou constante é praticamente irrisória, o momento angular de segunda ordem da GLCM mostra-se insuficiente para submissão num processo discriminante por MVG, pois a função de *Gauss* neste caso, não é capaz de modelar de forma aceitável a distribuição dos dados por esta variável.

Média (*Mean*): A variável espacial de textura, da função da média da matriz de coocorrência dos contadores digitais expressa a média em termos da GLCM.

$$\mu_{i,j} = \frac{\sum_{i,j=0}^{N-1} P_{i,j}}{N^2} \quad (50)$$

Onde:

$\mu_{i,j}$: média dos CDs na posição i,j

$P_{i,j}$: valor normalizado do CD para os *pixels* i e j

N : número de linhas ou de colunas

Desvio-padrão (*Standard Deviation*): A variável espacial de textura, da função de desvio-padrão da matriz de coocorrência dos contadores digitais, fornece uma medida de dispersão dos dados em torno da média em uma determinada direção, a uma certa distância.

$$\sigma = \sqrt{\sigma^2_{i,j}} \quad (51)$$

Onde:

σ : desvio-padrão

$\sigma^2_{i,j}$: variância dos CDs na posição i,j

Correlação (*Correlation*): A variável correlação fornece uma informação de medida de ordenação local dos CD's. A correlação apresenta-se padronizada de (0) a um (1). Quanto mais próximo estiver do valor 1, maior a correlação, implicando em uma maior afinidade linear positiva entre os CD's.

$$corr = \sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (52)$$

Onde:

$corr$: correlação

i : identificação da linha

j : identificação da coluna

$P_{i,j}$: valor normalizado do CD para os *pixels* i e j

μ_i : média dos CDs na linha i

μ_j : média dos CDs na coluna j

σ_i^2 : variância dos CDs na linha i

σ_j^2 : variância dos CDs na coluna j

N : número de linhas ou de colunas

3.3. UTILIZAÇÃO CONJUNTA DE ATRIBUTOS ESPECTRAIS E ESPACIAIS NO PROCESSO DE CLASSIFICAÇÃO

3.3.1. Seleção de Feições e Separabilidade Estatística

No processo de classificação de imagens digitais, um tópico importante refere-se à seleção do subconjunto de variáveis que se apresenta como o mais adequado ao processo de separar as classes envolvidas. Em outras palavras, busca-se um subconjunto de variáveis que apresente o maior poder discriminante entre as classes. Dado um conjunto de variáveis, freqüentemente ocorre que algumas variáveis são altamente correlacionadas, não contribuindo para incrementar o poder de discriminação entre as várias classes, mas aumentando desnecessariamente a dimensionalidade dos dados e com isto, o número de parâmetros a serem estimados. Esta situação torna-se especialmente nociva, quando o número de amostras de treinamento é pequeno, levando a uma degradação na performance do classificador (fenômeno de *Hughes*).

Por estas razões, uma etapa importante no processo de classificação refere-se à redução na dimensionalidade dos dados. De um modo geral, existem dois processos para atingir esta finalidade: seleção de feições e extração de feições. Os métodos de seleção de feições procuram definir qual o melhor subconjunto de variáveis para fins de separação entre as classes existentes, enquanto que os métodos de extração de feições aplicam transformações lineares sobre as variáveis originais, concentrando neste processo, a informação em um número menor de variáveis. Nesta dissertação o primeiro processo é utilizado.

Nos métodos de seleção de feições, a procura do subconjunto mais adequado de variáveis é selecionado, no sentido de maximizar a separação entre as classes conforme um critério previamente estabelecido. Dois dos critérios mais freqüentemente utilizados são: a Divergência e a distância de *Bhattacharyya*. Nesta dissertação será utilizado o critério da distância de *Bhattacharyya* para selecionar o par de classes mais distantes em cada nó da árvore.

a) Divergência

A Divergência utiliza como medida de separabilidade um par de distribuições de probabilidade. A Divergência está fundamentada no nível de sobreposição das distribuições, através da relação das verossimilhanças de um par de classes (RICHARDS, 1998).

Considerando duas classes w_i e w_j e a função decisão $G_i(X)$:

$$G_i(X) = p(X|w_i) \cdot P(w_i) \quad (53)$$

Pela regra do classificador *bayesiano*, se,

$$p(X|w_i) \cdot P(w_i) > p(X|w_j) \cdot P(w_j) \quad (54)$$

X pertence à classe w_i

Isolando as probabilidades *a priori* das classes ($P(w_i)$ e $P(w_j)$) que não variam em termos de X , temos:

$$L(X) = \Lambda_{(X)} = \frac{p(X|w_i)}{p(X|w_j)} > \frac{P(w_j)}{P(w_i)} \quad (55)$$

Considerando a posição no espaço dos atributos fornecidos pela relação entre as probabilidades *a priori* como o limiar (T) e sabendo que o resultado não será alterado se for utilizada uma função monotonamente crescente de (55),

$$L(X) = \Lambda_{(X)} = \ln \left\{ \frac{p(X|w_i)}{p(X|w_j)} \right\} > T \quad (56)$$

O valor esperado da divergência fica então como sendo a esperança matemática da probabilidade condicional de X ,

$$D = E\{\Lambda(X|w_j)\} - E\{\Lambda(X|w_i)\} \quad (57)$$

Utilizando a definição do $\Lambda_{(X)}$ a equação (57) fica,

$$D = \int_{-\infty}^{+\infty} \ln \left\{ \frac{p(X|w_i)}{p(X|w_j)} \right\} \cdot p(X|w_i) dx - \int_{-\infty}^{+\infty} \ln \left\{ \frac{p(X|w_i)}{p(X|w_j)} \right\} \cdot p(X|w_j) dx \quad (58)$$

Para os dados em sensoriamento remoto, sabe-se que as distribuições normais multidimensionais têm modelado de forma aceitável a distribuição dos dados, assim, ao se considerar que $p(X|w_i) \cdot P(w_i)$ e a $p(X|w_j) \cdot P(w_j)$ tenham distribuições normais, a equação (58) pela suposição de normalidade fica:

$$D = \frac{1}{2} \cdot \text{tr} \{ (\Sigma_i - \Sigma_j) (\Sigma_j^{-1} - \Sigma_i^{-1}) \} + \frac{1}{2} \cdot \text{tr} \{ (\Sigma_i^{-1} - \Sigma_j^{-1}) \cdot (M_i - M_j) \cdot (M_i - M_j)^T \}$$

Onde:

Σ_i : matriz covariância da classe i ;

Σ_j : matriz covariância da classe j ;

M_i : vetor de média da classe i ;

M_j : vetor de média da classe j .

a) Distância de *Bhattacharyya*

A distância de *Bhattacharyya* fornece uma medida de separabilidade entre duas classes. Ela é caracterizada como ótima quando utilizam-se um par de classes normais e sub-ótima para situações envolvendo mais de duas classes ao mesmo tempo (FUKUNAGA, 1990).

A forma geral da distância de *Bhattacharyya* é dada por:

$$b_{ij} = -\ln \left[\int_{-\infty}^{+\infty} \sqrt{(p(X|w_i)p(X|w_j))} dx \right] \quad (59)$$

Considerando que as classes w_i e w_j tenha distribuições normais, pode-se considerar que,

$$w_i = p(X|w_i)$$

$$w_j = p(X|w_j)$$

Assim, na suposição de normalidade dos dados a equação (59) fica:

$$b_{ij} = \frac{1}{8} \cdot (M_i - M_j)^T \cdot \left(\frac{\Sigma_i + \Sigma_j}{2} \right)^{-1} \cdot (M_i - M_j) + \frac{1}{2} \cdot \ln \left\{ \frac{|\Sigma_i + \Sigma_j|/2}{\sqrt{|\Sigma_i||\Sigma_j|}} \right\} \quad (60)$$

Onde:

b_{ij} : distância de *Bhattacharyya* entre as classes i e j

M_i : vetor de média da classe i

M_j : vetor de média da classe j

Σ_i : matriz de covariância da classe i

Σ_j : matriz de covariância da classe j

Quanto maior a distância de *Bhattacharyya*, maior será a separação entre as funções densidade de probabilidade das classes envolvidas, tornando assim, menor a probabilidade de erro e risco de *Bayes* a um classificador.

A distância de *Bhattacharyya* apresenta ainda outras aplicações interessantes, como por exemplo, na estimação de limiares para o erro de *Bayes* (FUKUNAGA, 1990).

$$\frac{1}{2} \left(1 - \sqrt{1 - e^{-2b_{ij}}} \right) \leq \epsilon_B \leq \frac{1}{2} e^{-b_{ij}} \quad (61)$$

No processo de seleção de feições, métricas para estimar a separação entre as classes, como a Divergência ou a distância de *Bhattacharyya* são utilizadas em processos que implementam buscas entre as variáveis disponíveis. Este processo de busca é normalmente pesado em termos computacionais, o que torna uma busca exaustiva normalmente proibitiva. Os métodos propostos procuram otimizar este processo de busca, adotando para esta finalidade critérios próprios. Na seção seguinte está descrito o processo SFS, adotado nesta dissertação.

3.3.2. Seqüencial Foward Selection (SFS)

A seleção seqüencial progressiva (*Sequential Forward Selection - SFS*) é um método *bottom-up* de seleção de feições, estruturado de modo a identificar iterativamente o melhor subconjunto de feições que possa ser obtido pela adição de uma feição por iteração, ao invés de selecionar um conjunto completo de feições numa única iteração. Uma particularidade que o SFS apresenta é que a feição uma vez selecionada não pode ser descartada, o que o torna sub-ótimo.

O algoritmo SFS seleciona os melhores atributos que representam um conjunto de classes a partir de um critério de seleção. O processo inicia-se com um

conjunto de variáveis nulas, de modo que, em cada iteração é selecionada a variável que produza o melhor resultado segundo um determinado critério. Tradicionalmente são utilizadas como critério, medidas estatísticas de separabilidade. Assim, iterativamente, cada variável é adicionada ao conjunto de variáveis determinadas pelas interações anteriores. Nesse processo não é permitido descartar uma variável que já tenha sido selecionada. Isso proporciona um efeito chamado de *nesting*, que ocorre quando um subconjunto ótimo não contém elementos do conjunto já selecionado.

Sendo V um conjunto completo de variáveis, com m indicando o número de iterações e partindo de X o subconjunto vazio de V com m variáveis e utilizando como critério de separabilidade estatística a distância de *Bhattacharyya* entre as classes i e j b_{ij} . O algoritmo SFS pode ser visto como:

Algoritmo SFS (V, X, m)

$$X \leftarrow \phi$$

Entrada: V : conjunto completo de variáveis

m : número de variáveis a ser selecionada (dimensão do subconjunto de X)

Saída: X : subconjunto de V com m variáveis

Laço: enquanto $|X| < m$ faça

$$X \leftarrow X \cup \left\{ \max_{1 \leq k \leq N} b_{ij}(f_k), \forall f_k \notin X \right\}$$

Retorne X

Onde

b_{ij} : distância de *Bhattacharyya* entre as classes i e j

f_k : feição K do conjunto completo de V

N : total de variáveis de V

Outras abordagens sub-ótimas, similares ao SFS são propostas na literatura. A SBS (*Seqüencial Backward Selection*) que é um método top-down que segue a mesma proposta e os métodos SFFS (*Seqüencial Forward Floating Selection*) e SBFS (*Seqüencial Backward Floating Selection*) que permitem a exclusão e a inclusão, respectivamente, de feições rejeitadas e adicionadas.

EXPERIMENTOS

Neste capítulo estão descritos os experimentos realizados em referência ao Classificador de Decisão em Árvore, sobre os dados imagem do sistema *Quickbird*, assim como, a estrutura da metodologia empregada, apresentada no capítulo 3.

Uma breve descrição das características dos dados imagem e os materiais utilizados são apresentados no início deste capítulo, seguidos dos experimentos empíricos de segmentação e da avaliação das variáveis espectrais e espaciais geométricas e de texturas, geradas destes segmentos.

A definição das classes de informação e a investigação do comportamento e das aproximações quanto às distribuições das classes, segundo o espaço multivariado, estruturado por objetos, propuseram uma preliminar seleção das variáveis que seriam submetidas aos experimentos realizados sobre o CDA.

Os experimentos iniciais do CDA foram delineados a partir da variação do número de feições utilizadas em cada nó da árvore, partindo da utilização de todo conjunto de amostras de treinamento disposto. Nesta etapa, investigou-se as características das árvores geradas, conforme a variação de 5, 10, 15 e 20 feições por nó, sobre a utilização conjunta das variáveis espectrais e espaciais. Sendo 31 variáveis propostas, 14 variáveis espectrais e 17 variáveis espaciais.

Na metodologia do CDA somente as classes que cumprirem certo critério de pertinência serão herdadas para os nós descendentes. Esse critério apresenta o conceito de limiar de verossimilhança, que representa um fator mínimo de verossimilhança que certa classe deve apresentar para ser classificada no nó descendente. Os demais experimentos foram partidos da investigação das árvores segundo a variação dos limiares de verossimilhança (LV) de 80%, 90%, 95% e 99%. Sobre cada LV foram utilizadas as mesmas variações no número de feições por nó, resultando numa totalidade de 16 árvores. Em todos os experimentos foram utilizadas sete classes.

A avaliação da acurácia individual de cada classe, para cada árvore, foi auferida pelo método *hold-out*, através das amostras de testes obtidas por simples seleção nos dados imagem. Essa avaliação permitiu a determinação do melhor CDA, ou seja, daquela que produza a melhor acurácia para um conjunto de classes. Utilizou-se como medidas de acurácia, o índice *kappa*, a acurácia média do classificador e do usuário.

Investigou-se ainda, comparações da presente proposta frente aos métodos convencionais de classificação em estágio único baseada no padrão *pixel*, como forma complementar de avaliação da eficiência do CDA.

Os experimentos de segmentação e a geração das variáveis dos atributos foram realizadas através do software comercial *eCogniton*. A implementação dos demais experimentos foram realizadas através do desenvolvimento de um algoritmo em ambiente *Matlab*. O Anexo 7 apresenta as rotinas desenvolvidas.

4.1. MATERIAIS

Para realização deste trabalho de pesquisa foram utilizados os seguintes materiais:

- Computador tipo PC com processador Pentium IV 2.8 GHz, 1024 Mb e demais componentes;
- Dados imagem do sistema *Quickbird* com as bandas pancromática e multiespectral;
- Software *Matlab* 7.0;
- Software *eCognition* 4.0;
- Software *ERDAS Imagine* 8.5;
- Software *ArcGIS* 9.1;
- Software *Multispec*.

4.2. ÁREA DE ESTUDO

A área de estudo situa-se no perímetro urbano do município de Porto Alegre, localizado ao centro-leste do estado do Rio Grande do Sul, na região sul do Brasil. Os dados imagem estão apresentados sobre o limites geográficos entre as longitude de 51° 13.4' W e 51° 15.0' W e as latitudes de 30° 3.5' S e 30° 6.0' S, abrangendo um área total de 11, 5 km². Uma imagem de referência geral está apresentada na Figura 19.

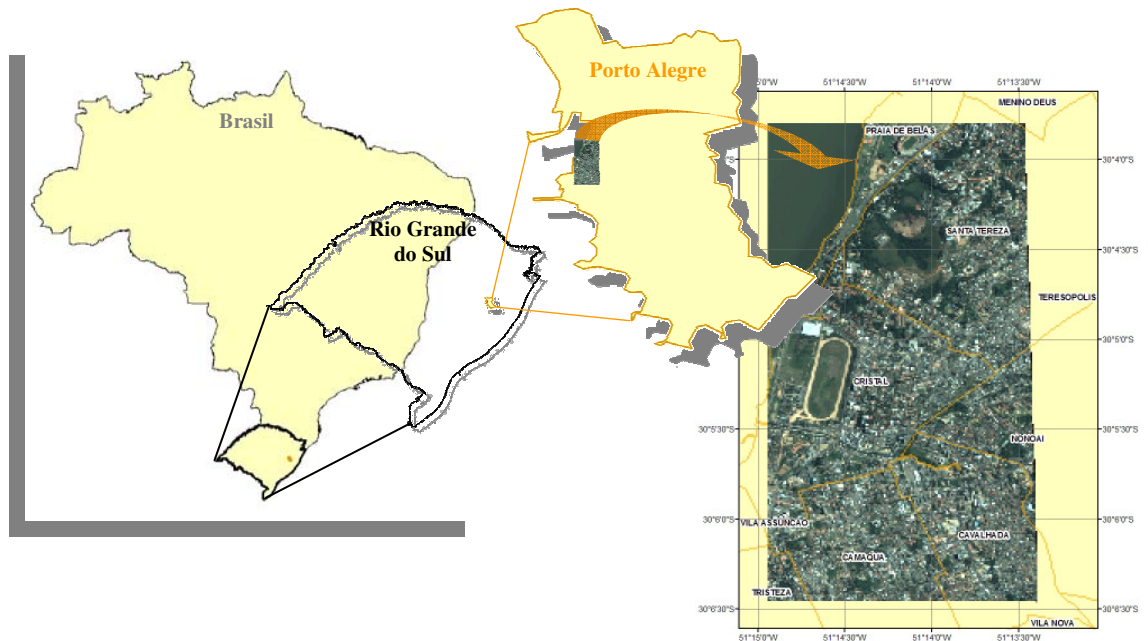


Figura 19 – Referência quanto à localização espacial dos dados imagem *Quickbird* da área de estudo

4.3. CARACTERÍSTICAS DOS DADOS IMAGEM


O conjunto de experimentos realizados utilizou-se essencialmente dos dados imagem fornecidos pelo sistema *Quickbird*, compostos por dois domínios de dados. O primeiro com resolução espacial de 2.4 metros, compostos por uma cobertura de quatro faixas espectrais, três no visível e uma no infra-vermelho próximo (cobertura multiespectral). O segundo com resolução espacial de 0.6 metros e cobertura espectral com uma única faixa que vai desde o visível até o infra-vermelho próximo (cobertura pancromática). Demais características dos dados imagem do sistema *Quickbird* estão apresentadas no Anexo 1.

Como um dos objetos de investigação desta dissertação está voltado à utilização combinada dos atributos espectrais e espaciais, o uso separado dos dois domínios de dados não compreendem os requisitos desejados para formatação da

proposta de classificação. Os dados imagem com cobertura multiespectral carregam as principais informações para constituição dos atributos espectrais, enquanto que os dados imagem com cobertura pancromática carregam a principal informação para formação dos atributos espaciais.

Frente a essa situação, determinou-se a utilização combinada dessa informação, a partir da criação de uma banda híbrida portadora das informações espectrais (banda multiespectral) e espaciais (banda pancromática), de modo que o conjunto de dados imagem resultante possuam a resolução espectral das quatro faixas espectrais com resolução espacial de 0.6 metros.

Para isso, utilizou-se do processo de fusão de imagens, substituindo a informação da primeira componente principal do conjunto de dados imagem multiespectral pela banda pancromática. Conforme as seguintes etapas:



Na 1ª etapa realiza-se a transformação dos dados imagem multiespectral (B, G, R, IR) pela análise de componentes principais (PCA), de modo a representar as quatro primeiras componentes (PCA1, PCA2, PCA3, PCA4). Na 2ª etapa substitui-se a primeira componente principal (PCA1) pelos dados imagem da cobertura pancromática (PAN). E por fim, na 3ª etapa procede-se a transformação inversa, das componentes principais para o formato multiespectral.

Os dados imagem das bandas multiespectrais, representada em cor verdadeira, da banda pancromática e da banda híbrida (fusionada) estão apresentadas no Anexo 2, 3 e 4, respectivamente.

4.4. EXPERIMENTOS DE SEGMENTAÇÃO

Os experimentos de segmentação foram constituídos pelo método multiresolução, conforme apresentado no capítulo 3.1.2., através do software comercial *eCognition*.

Esses experimentos partiram da utilização da segmentação em níveis, sob o uso da variação quantitativa em ordem crescente e decrescente dos parâmetros que formam o critério de homogeneidade.

A proposta dos experimentos de segmentação é o de encontrar o nível de segmentação que melhor representem os limites dos elementos reais apresentados nos dados imagem original, estruturados com o menor efeito possível de representação de *over-segmentation* e *under-segmentation*.

Como a resolução dos objetos produzidos pelo método de segmentação multiresolução é dada pela relação do parâmetro de escala, cada nível de segmentação irá propor um tamanho médio de objetos. Para encontrar então estes níveis foram utilizadas algumas combinações possíveis entre o conjunto de variáveis envolvidas. Essas combinações partiram do conhecimento prévio em experimentos de segmentação multiresolução.

O primeiro conjunto de experimentos foi definido com a proposição de criar oito níveis de segmentação (oito dados imagem segmentadas) variando segundo a ordem crescente do parâmetro de escala, com maior ponderação inicial aos critérios de forma e menor ao critério de cor. A proposta então é a de encontrar o nível que produza objetos mais próximos possível daqueles desejados pelo usuário. O incremento dos critérios envolvidos segue conforme a Tabela 1.

Tabela 1 – Ponderações ao critério de homogeneidade conforme níveis de segmentação do primeiro conjunto de experimentos

Nível	Parâmetro de Escala	Critério de Cor	Critério de Forma	Fator de Suavidade	Fator de Compactação
1	10	0.1	0.9	0.5	0.5
2	20	0.2	0.8	0.5	0.5
3	30	0.3	0.7	0.5	0.5
4	40	0.4	0.6	0.5	0.5
5	50	0.5	0.5	0.5	0.5
6	100	0.6	0.4	0.5	0.5
7	150	0.7	0.3	0.5	0.5
8	200	0.8	0.2	0.5	0.5

Cada nível de segmentação resultará em objetos com diferentes dimensões e formas. Como o parâmetro de escala é inicialmente menor, os limites dos objetos possuem dimensão proporcionalmente menor e o processo de criação de um nível de segmentação maior, parte da fusão dos objetos de menor escala, sem que haja alteração no limite dos objetos. Com base nos critérios de cor e de forma e dos parâmetros de suavidade e compactação é realizado o processo de fusão.

A Figura 20 apresenta um pequeno recorte dos dados imagem segmentados em quatro níveis, nível 5, 6, 7 e 8.

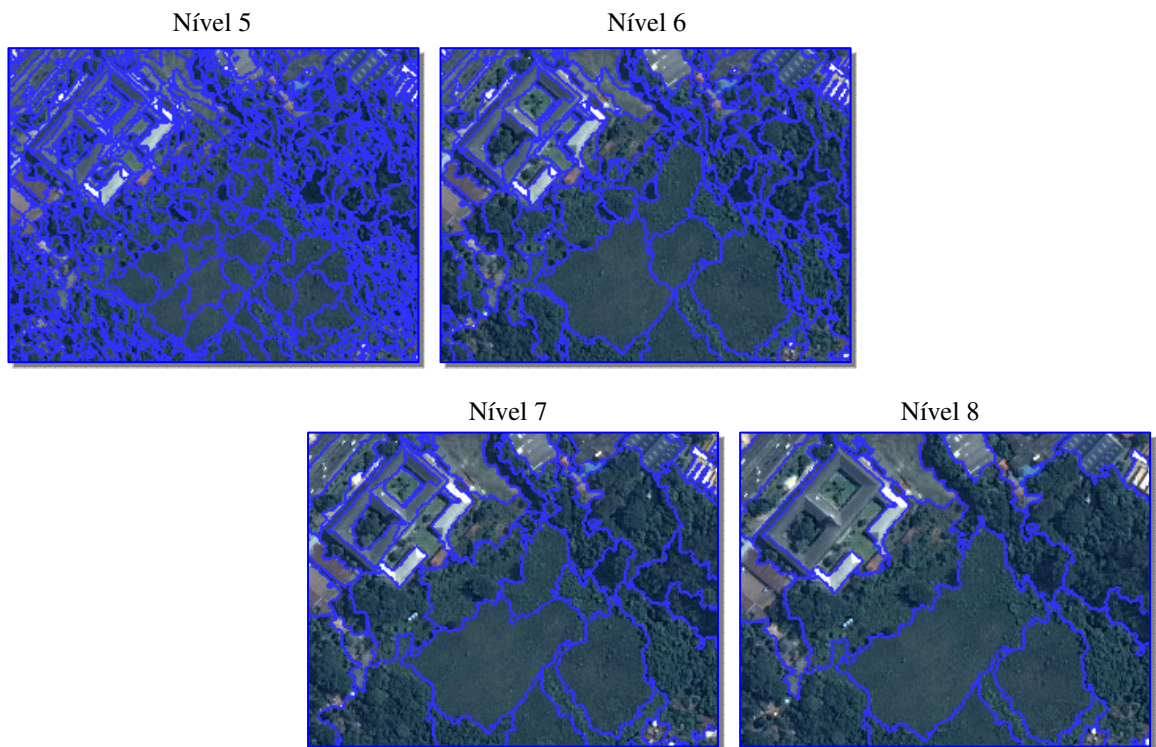


Figura 20 – Níveis de segmentação do primeiro conjunto de experimentos

Algumas estatísticas do resultado da segmentação estão apresentadas na Tabela 2, que podem servir como base de referência comparativa, quando de posse das estatísticas dos limites reais, oriundas, por exemplo, de um processo de restituição fotogramétrica. A unidade de medida apresentada está relacionada ao parâmetro de escala, que é um valor relativo da máxima mudança de heterogeneidade, causada pela fusão dos segmentos. O parâmetro de escala está assim relacionado com o tamanho dos objetos devido à dependência linear com a heterogeneidade.

Tabela 2 – Estatísticas do resultado de segmentação do primeiro conjunto de experimentos

Nível	Dimensão Mínima	Dimensão Máxima	Número de Objetos	Média	Variância	Moda
1	10	78.77	124193	19.06	49.61	7.04
2	20	186.60	54890	39.21	239.51	30.00
3	30	289.03	34793	59.95	590.88	45.54
4	40	472.69	25251	80.99	1132.22	47.75
5	50	493.17	19457	102.98	1924.36	76.60
6	100	996.58	6456	196.74	6366.15	153.86
7	150	1155.18	3211	292.64	13867.53	170.18
8	200	1481.54	1901	395.23	25208.53	225.70

O segundo conjunto de experimentos também foi definido com o propósito de criar oito níveis de segmentação, variando segundo ordem crescente do parâmetro de escala, utilizando agora maior fator de ponderação inicial aos critérios de cor e menor aos critérios de forma. O incremento destes critérios seguiu conforme a Tabela 3.

Tabela 3 – Ponderações ao critério de homogeneidade conforme níveis de segmentação do segundo conjunto de experimentos

Nível	Parâmetro de Escala	Critério de Cor	Critério de Forma	Fator de Suavidade	Fator de Compactação
1	10	0.9	0.1	0.5	0.5
2	20	0.8	0.2	0.5	0.5
3	30	0.7	0.3	0.5	0.5

Nível	Parâmetro de Escala	Critério de Cor	Critério de Forma	Fator de Suavidade	Fator de Compactação
4	40	0.6	0.4	0.5	0.5
5	50	0.5	0.5	0.5	0.5
6	100	0.4	0.6	0.5	0.5
7	150	0.3	0.7	0.5	0.5
8	200	0.2	0.8	0.5	0.5

Como a decisão para fusão dos objetos está baseada no critério de homogeneidade e este sobre os critérios de cor e forma, o segundo conjunto de experimentos proporcionou a criação de diferentes limites de objetos em cada nível.

As estatísticas em relação aos segmentos gerados para o segundo conjunto de experimentos estão apresentadas na Tabela 4.

Tabela 4 – Estatísticas do resultado de segmentação do segundo conjunto de experimentos

Nível	Dimensão Mínima	Dimensão Máxima	Número de Objetos	Média	Variância	Moda
1	10	123,8	542440	19.31	57.64	16.51
2	20	246.7	139090	40.77	309.86	25.42
3	30	322.21	61288	62.13	722.01	35.85
4	40	407.45	33569	82.19	1209.71	47.35
5	50	484.69	20423	100.90	1697.27	76.08
6	100	854.66	5080	186.63	4583.49	145.28
7	150	818.64	1808	266.01	8051.98	217.05
8	200	805.75	641	360.03	11861.19	236.79

Dois critérios de seleção foram adotados para obtenção dos dados imagem segmentado a ser utilizado nas demais etapas do desenvolvimento. O primeiro refere-se à análise aproximada do número de objetos da região, a partir dos dados disponíveis por restituição fotogramétrica pela Secretaria de Planejamento Municipal da Prefeitura de Porto Alegre. Para mensuração do número de objetos utilizou-se os principais vetores no formato poligonal na região coberta pelos limites dos dados imagem, de modo a obter uma pré-seleção dos níveis mais próximos à realidade. O número de objetos medido foi de 5569 objetos para a toda a região. Sabe-se que este valor serve apenas como uma aproximação visto que sobre a restituição fotogramétrica, muitos elementos não estão representados devido à seleção no processo de restituição e devido à datação distinta dos dois conjuntos de dados.

A partir disso, selecionou-se os dados do nível 6 e 7 do primeiro e do segundo conjunto de experimentos e sobre estes quatro níveis, definiu-se por análise visual, em sobreposição dos segmentos aos dados imagem original, o nível mais adequado.

Selecionou-se o nível 6 do primeiro conjunto de experimentos como os dados imagem segmentados mais adequados, de acordo avaliação qualitativa do limite dos objetos produzidos por este nível de segmentação em relação à borda dos elementos reais apresentados pelos dados imagem original.

4.5. ATRIBUTOS ESPECTRAIS E ESPACIAIS

A obtenção das variáveis espectrais e espaciais foram realizadas através do software *eCognition*. Nessa etapa, a partir dos dados imagem segmentados no nível 6 do primeiro conjunto de experimentos de segmentação, selecionou-se as variáveis espectrais e espaciais apresentadas nos capítulos 3.2.1 e 3.2.2 e sobre cada variável

procedeu-se a conversão para o formato vetorial no padrão do software *ArcGIS* (*shapefile*).

Para identificação comum dos atributos dos objetos, ou seja, do valor de cada variável, criou-se um identificador único sobre cada objeto, de modo que qualquer objeto carregue a quantificação de todas as variáveis espectrais e espaciais. Isso proporcionou a criação de uma matriz de variáveis de dimensão $n \times m$, onde n indica o número total de objetos e m o número total de atributos. Essa identificação será única em todas as etapas do desenvolvimento nos experimentos seguintes.

A informação sobre cada linha da matriz carrega a informação de todas as variáveis de um único objeto e cada coluna da matriz a informação de uma única variável em relação a todos os objetos, ou seja, para todos dados os dados imagem. A Tabela 5 apresenta a estrutura dessa matriz e a Figura 21 ilustra a identificação única de cada objeto sobre as variáveis espectral, espacial (geometria) e espacial (textura), respectivamente, no formato vetorial.

Tabela 5 - Estrutura da matriz de objetos e variáveis

Identificação do Objeto	Variável 1	Variável 2	Variável 3	Variável 4	...	Variável m
0	V_{01}	V_{02}	V_{03}	V_{04}	...	V_{0m}
1	V_{11}	V_{12}	V_{13}	V_{14}	...	V_{1m}
2	V_{21}	V_{22}	V_{23}	V_{24}	...	V_{2m}
\vdots	\vdots	\vdots	\vdots	\vdots		\vdots
n	V_{n1}	V_{n2}	V_{n3}	V_{n4}	...	V_{nm}




Figura 21 – Exemplo de identificação de objetos em cada variável espectral, espacial (geometria) e espacial (textura), respectivamente

4.6. AMOSTRAS DE TREINAMENTO E DE TESTES

A etapa que precedeu à seleção das amostras diz respeito à definição das classes de informação. A partir da interpretação conjunta dos dados imagem e dos segmentos definiu-se trabalhar com as seguintes classes de informação: edificações (telhado claro), edificações (telhado escuro), edificações (telhado cerâmica), vegetação arbórea, vegetação rasteira, solo exposto, vias e hidrografia.

A proposta inicial buscava distinguir as classes de edificações segundo as classes espectrais relacionadas, por: edificação com coberturas de telhado de zinco, amianto, cerâmica e concreto. Essa definição mostrou-se inapta à formação e a discriminação, haja visto a grande variedade de padrões formados por estas classes, generalizando-as assim, como supracitado.

Para seleção das amostras de treinamento e de testes utilizou-se o software comercial *ArcGIS*, definindo sobre os registros selecionados na matriz de objetos e variáveis, a identificação da classe para cada um desses objetos.

Como os demais processos experimentais seguem no uso do desenvolvimento de algoritmos no ambiente *Matlab*, a matriz de objetos e variáveis,

com as amostras selecionadas, foi exportada para um formato comum de leitura entre os softwares *Matlab* e *ArcGIS*, mantendo a possibilidade de posterior comunicação e manipulação dos dados.

4.7. SELEÇÃO PRELIMINAR DAS VARIÁVEIS E CLASSES DE INFORMAÇÃO

O principal critério para seleção das variáveis e das classes de informação, que serão dispostas ao CDA, são a normalidade dos dados e a quantidade de amostras, respectivamente. A normalidade dos dados foi verificada por aproximação visual através de análise dos histogramas.

A Tabela 6 apresenta as variáveis selecionadas e rejeitadas à utilização no processo de CDA. A identificação da variável na primeira coluna da tabela manterá a referência com a denominação das variáveis aos demais experimentos envolvidos nesta dissertação.

Tabela 6 – Status da seleção das variáveis espectrais e espaciais

Atributos Espectrais		Status
Variável 1	Média – Banda 1	Selecionado
Variável 2	Desvio-padrão – Banda 1	Selecionado
Variável 3	Razão – Banda 1	Selecionado
Variável 4	Média – Banda 2	Selecionado
Variável 5	Desvio-padrão – Banda 2	Selecionado
Variável 6	Razão – Banda 2	Selecionado
Variável 7	Média – Banda 3	Selecionado
Variável 8	Desvio-padrão – Banda 3	Selecionado
Variável 9	Razão – Banda 3	Selecionado
Variável 10	Média – Banda 4	Selecionado

Variável 11	Desvio-padrão – Banda 4	Selecionado
Variável 12	Razão – Banda 4	Selecionado
Variável 13	Brilho	Selecionado
Variável 14	Diferença Máxima	Selecionado

Atributos Espaciais (Geometria)

Variável 15	Área	Selecionado
Variável 16	Comprimento	Selecionado
Variável 17	Largura	Selecionado
Variável 18	Comprimento/Largura	Selecionado
Variável 19	Compactação	Selecionado
	Ajuste Elíptico	Rejeitado
Variável 20	Ajuste Retangular	Selecionado
Variável 21	Comprimento da Borda	Selecionado
Variável 22	Índice de Forma	Selecionado
Variável 23	Densidade	Selecionado
	Direção Principal	Rejeitado
	Assimetria	Rejeitado

Atributos Espaciais (Textura)

Variável 24	Homogeneidade GLCM	Selecionado
Variável 25	Contraste GLCM	Selecionado
Variável 26	Dissimilaridade GLCM	Selecionado
Variável 27	Entropia GLCM	Selecionado
	Momento Ang. de 2ª ordem GLCM	Rejeitado
Variável 28	Média GLCM	Selecionado
Variável 29	Desvio-padrão GLCM	Selecionado
Variável 30	Correlação GLCM	Selecionado
	Momento Ang. de 2ª ordem GLDV	Rejeitado
Variável 31	Entropia GLDV	Selecionado

A quantidade de amostras de treinamento e de testes para cada classe foi o critério seleção das classes de informação, sendo que apenas a classe hidrografia forneceu uma quantidade praticamente inexpressiva para obtenção das estatísticas da classe e por conseqüência à definição de um padrão. A Tabela 7 apresenta estas quantidades.

Tabela 7 – Quantidade de amostras de treinamento e de testes por classes de informação

Classe	Amostras de Treinamento	Amostras de Teste	Total de Amostras
Telhado Claro	93	93	186
Telhado Escuro	64	63	127
Telhado Cerâmica	79	79	158
Vegetação Arbórea	84	84	168
Vegetação Rasteira	105	104	209
Solo Exposto	69	69	138
Vias	64	63	127
Hidrografia	15	15	30

As assinaturas (espectrais/espaciais) das classes selecionadas, utilizando o valor média e o desvio-padrão de cada variável, foram plotadas para verificar o comportamento geral (individual e combinado) dos atributos e das classes. As imagens apresentadas entre as Figuras 22 e a Figura 29 apresentam estas assinaturas, onde no eixo horizontal estão representados pelos atributos, ordenado conforme a Tabela 6 e no eixo vertical estão representados os valores de cada atributo, padronizado em 8 bits.

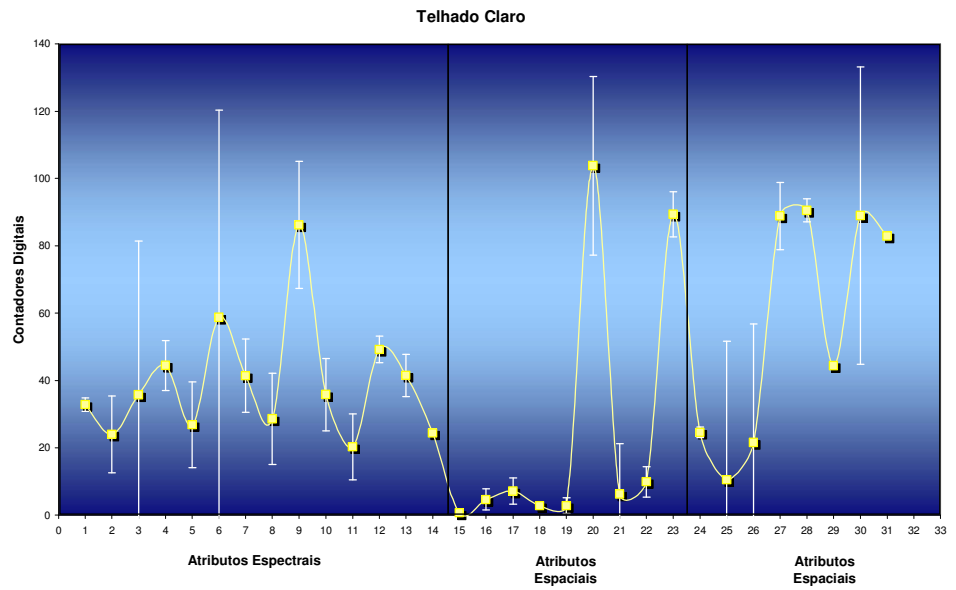


Figura 22 – Assinatura espectral/espacial para a classe Edificação – Telhado Claro

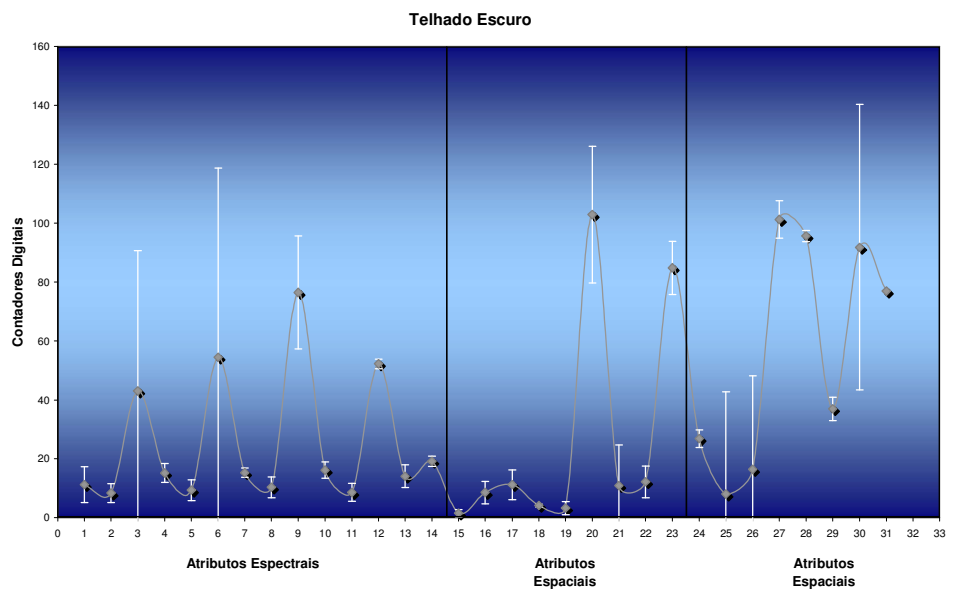


Figura 23 – Assinatura espectral/espacial para a classe Edificação – Telhado Escuro

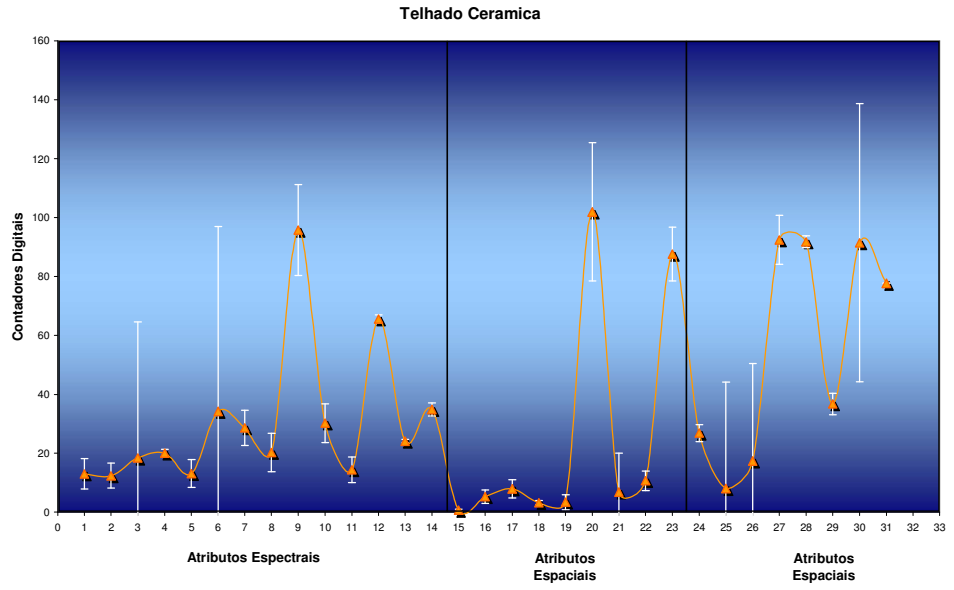


Figura 24 – Assinatura espectral/espacial para a classe Edificação – Telhado Cerâmica




Figura 25 – Assinatura espectral/espacial para a classe Vegetação Arbórea




Figura 26 – Assinatura espectral/espacial para a classe Vegetação Rasteira

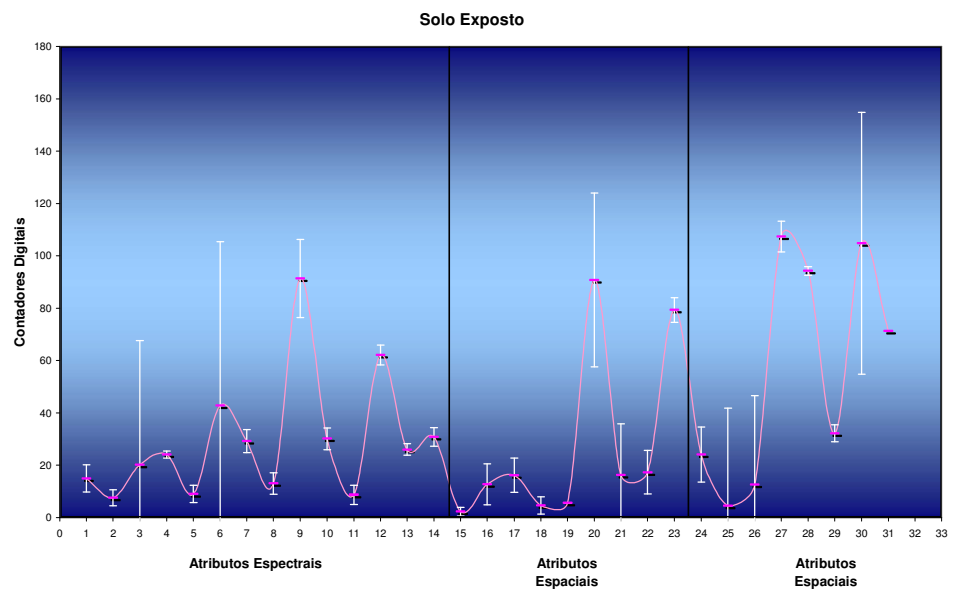


Figura 27 – Assinatura espectral/espacial para a classe Solo Exposto




Figura 28 – Assinatura espectral/espacial para a classe Vias




Figura 29 – Assinaturas espectral/espacial para as sete classes de informação

4.8. EXPERIMENTOS DO CDA

4.8.1. Construção da Árvore de Decisão

A primeira etapa para classificação em decisão em árvore é a construção das árvores de decisão. A estrutura da árvore utilizada é da forma de hierarquia binária, proporcionando que somente duas classes sejam consideradas em cada nó. A principal vantagem que essa estrutura apresenta é de permitir a seleção mais adequada das variáveis espectrais e espaciais em cada nó, ao lugar de selecionar um conjunto de variáveis que apresente a maior separabilidade da totalidade de classes, como é o caso dos classificadores em estágio único.

A construção da árvore na estrutura binária, pelo método *bottom-up*, apresentado no capítulo 2.7, segue as seguintes etapas:

1. Definição do par de classes mais distantes do nó;
2. Aplicação do algoritmo de SFS para seleção dos m atributos mais representativos;
3. Classificação das demais classes para os nós descendentes;
4. O processo acima é repetido até que só haja uma classe no nó (nó terminal).

Na etapa 1, a definição do par de classes mais distantes, parte da totalidade de classes apresentadas no nó, utilizando as 31 variáveis disponíveis, pelo critério da distância de *Bhattacharyya* máxima, equação (60). Nesse caso são realizados por nó a medida de 21 distâncias (C_7^2). Cada classe, do par de classes pertencentes à maior distância, é atribuída a um nó descendente distinto (no nó da direita e nó da esquerda). A estrutura binária sempre irá apresentar para cada nó apenas dois nós descendentes.

Na etapa 2, é realizada a seleção do conjunto de m variáveis que apresentam o maior poder discriminante com relação ao par de classes, anteriormente selecionados, a partir do critério de seleção do conjunto de variáveis que maximizam a distância de *Bhattacharyya* (algoritmo SFS). Nesta etapa são realizadas $\sum_{k=1}^m 31-k$ medidas de distâncias, sendo que a cada iteração é incorporada uma nova variável ao conjunto.

Na etapa 3, cada nó descendente possui um conjunto de variáveis definidos pelo processo de SFS e uma classe obtida pelo critério da distância máxima de separabilidade. Para essa classe, com estas variáveis, é definida uma função discriminante pela máxima verossimilhança gaussiana, dada pela equação (10). Com as funções discriminantes de $G(w_i)$ (classe do nó da direita) e $G(w_j)$ (classe do nó da esquerda), classifica-se cada uma das demais classes do nó anterior para os nós descendentes (da esquerda e/ou da direita) conforme um critério de pertinência pré-estabelecido (limiar de verossimilhança). O limiar de verossimilhança dirá respeito então, à fração mínima de amostras de treinamento de uma classe k que precisam ser classificados nos nós descendentes para a classe toda seja considerada como pertencente a um destes nós (nó vencedor ou nós vencedores). Toda a classe cujas amostras não satisfizerem este critério fica atribuída a ambos os nós descendentes.

Estas três etapas do processo do CDA são repetidas para os demais nós até que em cada nó esteja somente uma classe atribuída. Este nó dará o rótulo do padrão e é denominado de nó terminal.

Considerando a estrutura citada, resolve-se exemplificar a construção da árvore, supondo o seguinte conjunto de parâmetros:

- Classes: **A, B, C e D**
- Variáveis: **V1, V2, V3, V4, V5 e V6.**
- Limiar de verossimilhança: 80%
- Seleção de feições para 3 variáveis;

Sendo **n1**, **n2**, **n3**, ..., **n15** a quantidade de nós, a estrutura inicial da árvore pode ser apresentada pela Figura 30.




Figura 30 – Estrutura inicial do CDA em estrutura binária pelo método *bottom-up* (exemplo sintético)

Na 1ª etapa são definidas as classes que vão compor os dois nós descendentes pelo critério da distância de *Bhattacharyya* máxima, realizando as seguintes medidas: b_{ab} , b_{ac} , b_{ad} , b_{bc} , b_{bd} e b_{cd} . A maior destas distâncias definirá os nós descendentes (**n2** e **n3**). Supõem-se b_{ac} como a maior distância, assim a classe **A** é atribuída ao nó **n2** e a classe **C** ao nó **n3**.

Na 2ª etapa define-se o melhor conjunto U de 3 variáveis dentre as seis variáveis disponíveis, para fins de utilização no processo de classificação. Estas variáveis serão as utilizadas para estimar os parâmetros do classificador (vetor de médias e matriz de covariância) para as classes **A** e **C**. No primeiro passo do SFS são realizadas então 6 medidas de b_{ac} , cada uma com apenas um variável. A maior das distâncias é recebida pelo conjunto U . Supondo **V4**. No segundo passo são realizadas 5 medidas de b_{ac} , com as variáveis **V4V1**, **V4V2**, **V4V3**, **V4V5**, **V4V6**. A maior dessas medidas é incorporada à U , supõem-se **V4V6**. No terceiro e último passo são realizadas 4 medidas de b_{ac} , com as variáveis **V4V6V1**, **V4V6V2**, **V4V6V3**, **V4V6V5**. Supondo o conjunto formado por **V4V6V3** possua a maior distância, define-se o conjunto U como U (**V3**, **V4**, **V6**). A árvore apresentada pela Figura 30 fica como a Figura 31.




Figura 31 – CDA em estrutura binária com as variáveis selecionadas pelo SFS no nó raiz (exemplo sintético)

Na 3ª etapa são definidas as funções discriminantes pela máxima verossimilhança gaussiana, $G_A(X)$ e $G_C(X)$, onde os vetores de média de **A** (m_A) e de **C** (m_C) e as matrizes de covariância de **A** (Σ_A) e de **C** (Σ_C) são:

$$m_A = \begin{bmatrix} m_{AV3} \\ m_{AV4} \\ m_{AV6} \end{bmatrix} \quad m_C = \begin{bmatrix} m_{CV3} \\ m_{CV4} \\ m_{CV6} \end{bmatrix}$$

$$\Sigma_A = \begin{bmatrix} \sigma_{AV3}^2 & \sigma_{AV3V4} & \sigma_{AV3V6} \\ \sigma_{AV3V4} & \sigma_{AV4}^2 & \sigma_{AV4V6} \\ \sigma_{AV3V6} & \sigma_{AV4V6} & \sigma_{AV6}^2 \end{bmatrix} \quad \Sigma_C = \begin{bmatrix} \sigma_{CV3}^2 & \sigma_{CV3V4} & \sigma_{CV3V6} \\ \sigma_{CV3V4} & \sigma_{CV4}^2 & \sigma_{CV4V6} \\ \sigma_{CV3V6} & \sigma_{CV4V6} & \sigma_{CV6}^2 \end{bmatrix}$$

Classifica-se por $G_A(X)$ e $G_C(X)$ todos os padrões de X da amostra de treinamento da classe **B** e da classe **D**. Partindo da suposição que **B** possua 100 amostras e que destas, 90 amostras são mais verossímeis à classe **A** e 10 amostras a classe **C**. Como mais que 80% (limiar de verossimilhança) das amostras são mais verossímeis à classe **A**, define-se como nó vencedor para classe **B** o nó n2. Supondo que **D** possua também 100 amostras e que destas, 60 amostras são mais verossímeis à classe **A** e 40 amostras mais verossímeis à classe **C**. Como nenhuma das classes atingem o limiar de verossimilhança atribui-se como nó vencedor os nós **n2** e **n3**. A árvore então fica conforme a Figura 32.




Figura 32 – CDA em estrutura binária com apresentação das classes em nós descendentes (exemplo sintético)

O procedimento é repetido para todos os demais nós da árvore até que somente um par de classes esteja atribuído à um nó. A Figura 33 é um exemplo de uma árvore final para esse procedimento sintético.




Figura 33 – Árvore final de um CDA em estrutura binária (exemplo sintético)

4.8.2. Classificação com a Árvore de Decisão

A informação que cada árvore carrega após a sua construção, capítulo 4.8.1, pode ser resumida por:

- Cada nó possui um par de classes mais distinto e um conjunto próprio de variáveis;
- Para cada uma das classes tem-se uma função discriminante;

- ▀ As estatísticas desse par de classes (vetor de média e matriz de covariância) estão estruturadas pelo conjunto de variáveis definidas pelo SFS.

O processo de classificação com a árvore de decisão parte análise de verossimilhança de um dado padrão no nó raiz mediante a função discriminante da máxima verossimilhança gaussiana. Para o caso da avaliação da acurácia do CDA utilizam-se como padrões de entrada as amostras de testes das classes. Como cada uma destas classes é derivada para um nó descendente diferente, o padrão é direcionado ao nó relacionado à classe que for mais verossímil. Se o nó seguinte estiver representado por apenas uma classe (nó terminal), este fornecerá a rotulação ao padrão, caso contrário, repete-se procedimento de classificação com o par de classes mais distintos neste nó e seu conjunto próprio de variáveis.

Seguindo o esboço proposto no capítulo 4.8.1, a árvore de decisão fica:




Figura 34 – Árvore de decisão em estrutura binária (exemplo sintético)

Partindo da árvore apresentada pela Figura 34, sobre o nó **n1** as estatísticas das classes são estimadas pelo o vetor de médias e a matriz de covariância para as classes **A** e **C** das variáveis **V3**, **V4** e **V6**. No nó **n2**, com as classes **A** e **D** e as variáveis **V1**, **V2** e **V4**. No nó **n3**, com as classes **C** e **D** e as variáveis **V3**, **V5** e **V6** e nó **n4**, com as classes **C** e **D** e as variáveis **V1**, **V4** e **V5**.

Supondo um padrão único X , com seis variáveis, a classificação de decisão em árvore será dada da seguinte forma:

- Se $G_A(X) > G_C(X)$ o padrão segue para **n2**, caso contrário, o padrão segue para **n3**. Supondo que $G_A(X) > G_C(X)$ é verdadeiro.
- No nó **n2** verifica-se se $G_A(X) > G_C(X)$. Se verdadeiro o padrão segue para **n4**, senão, segue para **n5**. Supondo $G_A(X) < G_C(X)$, o padrão X recebe o rótulo da classe **D**.
- Encerra-se a classificação.

4.8.3. Experimento com Limiar de Verossimilhança de 80%

Os experimentos iniciais foram utilizados com um limiar fixo de verossimilhança, neste caso 80%, variando o número de feições por nó, definidos no processo de *SFS*, com 5, 10, 15 e 20 variáveis por nó, do total de 31 variáveis. Em todos os experimentos foram utilizadas sete classes de informação: Edificação – Telhado Claro (classe 1), Edificação – Telhado Escuro (classe2), Edificação – Telhado Cerâmica (classe 3), Vegetação Arbórea (classe 4), Vegetação Rasteira (classe 5), Solo Exposto (classe 6) e Vias (classe 7) e as denominação das variáveis está conforme a Tabela 6.

Utilizou-se em todos os experimentos, a distância de *Bhattacharyya* como critério para identificar em cada nó, o par de classes com a maior separabilidade. Para fins de seleção do subconjunto de feições a ser adotado em cada nó adotou-se o método *SFS*. O classificador adotado em cada nó foi o da Máxima Verossimilhança Gaussiana (MVG). Para construção dos CDAs utilizou-se a rotina *buildCDA*, desenvolvida nesta dissertação e apresentada no Anexo 7.

O experimento ilustrado na Figura 35 e na Figura 36 (CDA 1) utiliza 5 feições em cada nó e apresenta uma estrutura com 17 nós, sendo destes, 9 nós terminais.

A Figura 35 apresenta o conjunto de classes em cada nó, sendo o par de classes com maior separação apresentados pela cor em destaque. A Figura 36 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.




Figura 35 – CDA 1: LV de 80% e 5 feições em cada nó




Figura 36 – Variáveis definidas via SFS do CDA 1 com 5 feições em cada nó

Das variáveis selecionadas pelo experimento do CDA 1, em média 83% são de natureza espectral e 27% de natureza espacial. As variáveis espaciais estão dispostas somente nos nós **n6** (classes 2 e 7) e **n28** (classes 3 e 6), sendo que em **n6** somente atributos espaciais foram selecionados como mais representativos para o par de classes.

Para estimação da acurácia do CDA 1 classificaram-se as amostras de testes das classes (método de estimação: *hold-out*). Os erros envolvidos neste experimento dizem respeito principalmente à confusão entre as classes telhado de cerâmica (3) e solo exposto (6), onde a maioria dos objetos que deveriam ser classificados na classe 3 foram classificados na classe 1, resultando em uma acurácia extremamente baixa para as classes 3 e 6.

A acurácia geral estimada para o experimento CDA 1 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 63%. A acurácia do usuário para a grande maioria das classes foi superior a acurácia do produtor, de uma forma mais visível para o caso da classe 1, indicando a ocorrência de um número maior de erros de inclusão do que de omissão. A tabela de contingência, apresentando os erros e acurácias envolvidos está apresenta na Tabela 8.

Tabela 8 – Tabela de Contingência do CDA 1

Tabela de Contingência										
CDA 1										
Limiar de Verossimilhança 80%										
5 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	92,06%	63	1	58	0	0	4	0	0
Telhado Cerâmica	3	0,00%	79	75	3	0	0	1	0	0
Vegetação Arbórea	4	97,62%	84	0	0	0	82	2	0	0
Vegetação Rasteira	5	94,23%	104	4	0	0	2	98	0	0
Solo Exposto	6	0,00%	69	68	0	0	0	1	0	0
Vias	7	90,48%	63	0	6	0	0	0	0	57
Total de Amostras Classificadas na Classe			555	240	68	0	84	106	0	57
Acurácia (%) **				38,33%	85,29%	0,00%	97,62%	92,45%	0,00%	100,00%
Índice Kappa			64,10%							
Acurácia Média do Usuário			67,62%							
Acurácia Média do Produtor			59,10%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

O experimento ilustrado na Figura 37 e na Figura 38 (CDA 2) utiliza 10 feições em cada nó e apresenta uma estrutura com 15 nós, sendo destes, 8 nós terminais. A Figura 37 apresenta o conjunto de classes em cada nó, sendo o par de classes com

maior separação apresentada pela cor em destaque. A Figura 38 apresenta o conjunto de atributos seleccionados pelo SFS em cada um destes nós.




Figura 37 – CDA 2: LV de 80% e 10 feições em cada nó




Figura 38 – Variáveis definidas via SFS do CDA 2 com 10 feições em cada nó

Das variáveis seleccionadas pelo experimento do CDA 2, em média 83% são de natureza espectral e 17% de natureza espacial, sendo que 50% das variáveis espaciais do CDA 2 estão dispostas em **n28** (classes 3 e 6), representando 70% das variáveis no nó.

A avaliação da acurácia deste experimento seguiu o mesmo padrão apresentado anteriormente (*hold out*), fazendo uso de um conjunto de amostras de testes. Como para o CDA 1, os erros envolvidos nessa árvore dizem respeito principalmente à confusão entre as classes telhado de cerâmica (3) e solo exposto (6), onde a maioria dos objetos que deveriam ser classificados na classe 3 foram classificados na classe 1, resultando em uma acurácia extremamente baixa para as classes 3 e 6.

A acurácia geral estimada para o experimento CDA 2 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 64%, superior ao CDA 1. A acurácia do usuário para a grande maioria das classes foi superior a acurácia do produtor, de uma forma mais visível para o caso da classe 1, indicando a ocorrência de um número maior de erros de inclusão do que de omissão. A tabela de contingência, apresentando os erros e acurácias envolvidos está apresentada na Tabela 9.

Tabela 9 – Tabela de Contingência do CDA 2

Tabela de Contingência										
CDA 2										
Limiar de Verossimilhança 80%										
10 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	84,13%	63	0	53	0	0	4	0	6
Telhado Cerâmica	3	0,00%	79	76	3	0	0	0	0	0
Vegetação Arbórea	4	100,00%	84	0	0	84	0	0	0	0
Vegetação Rasteira	5	96,15%	104	3	1	0	0	100	0	0
Solo Exposto	6	0,00%	69	68	0	0	0	0	0	1
Vias	7	98,41%	63	0	1	0	0	0	0	62
Total de Amostras Classificadas na Classe			555	239	59	0	84	104	0	69
Acurácia (%) **				38,49%	89,83%	0,00%	100,00%	96,15%	0,00%	89,86%
Índice Kappa			64,97%							
Acurácia Média do Usuário			68,23%							
Acurácia Média do Produtor			59,19%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

O experimento apresentado na Figura 39 e na Figura 40 (CDA 3) utiliza 15 feições em cada nó e apresenta uma estrutura com 15 nós, sendo destes, 8 nós terminais,

como o CDA 2. A Figura 39 apresenta o conjunto de classes de cada nó, sendo o par de classes com maior separação apresentado pela cor em destaque. A Figura 40 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.




Figura 39 – CDA 3: LV de 80% e 15 feições em cada nó




Figura 40 – Variáveis definidas via SFS do CDA 3 com 15 feições em cada nó

Das variáveis selecionadas pelo experimento do CDA 3, em média 72% são de natureza espectral e 28% de natureza espacial, sendo que o nó com maior representação de variáveis espaciais continua sendo o **n28** (classes 3 e 6). Houve um acréscimo em 11% de utilização das variáveis espaciais em comparação aos CDA 1 e 2.

A avaliação da acurácia desta árvore seguiu o mesmo padrão apresentado anteriormente (*hold-out*). Neste conjunto de experimentos verifica-se que os erros envolvidos neste experimento dizem respeito principalmente à confusão entre as classes telhado de cerâmica (3) e solo exposto (6), onde a maioria dos objetos que deveriam ser classificados na classe 3 foram classificados na classe 1, resultando em uma acurácia extremamente baixa para as classes 3 e 6.

A acurácia geral estimada para o experimento CDA 3 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 65%, superior aos experimentos anteriores. A acurácia do usuário para a grande maioria das classes manteve-se superior à acurácia do produtor. A tabela de contingência, apresentando os erros e acurácias envolvidos está apresentada na Tabela 10.

Tabela 10 – Tabela de Contingência do CDA 3

Tabela de Contingência										
CDA 3										
Limiar de Verossimilhança 80%										
15 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	92,06%	63	0	58	0	0	3	0	2
Telhado Cerâmica	3	0,00%	79	76	3	0	0	0	0	0
Vegetação Arbórea	4	98,81%	84	0	0	0	83	1	0	0
Vegetação Rasteira	5	96,15%	104	3	1	0	0	100	0	0
Solo Exposto	6	0,00%	69	68	0	0	0	0	0	1
Vias	7	98,41%	63	1	0	0	0	0	0	62
Total de Amostras Classificadas na Classe			555	240	63	0	83	104	0	65
Acurácia (%) **				38,33%	92,06%	0,00%	100,00%	96,15%	0,00%	95,38%
Índice Kappa			65,83%							
Acurácia Média do Usuário			69,19%							
Acurácia Média do Produtor			60,28%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

O experimento ilustrado na Figura 41 e na Figura 42 (CDA 4) utiliza 20 feições em cada nó e apresenta uma estrutura similar aos CDA 2 e 3, com 15 nós, sendo destes, 8 nós terminais. A Figura 41 apresenta o conjunto de classes de cada nó, sendo o

par de classes com maior separação apresentado pela cor em destaque. A Figura 42 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.




Figura 41 – CDA 4: LV de 80% e 20 feições em cada nó




Figura 42 – Variáveis definidas via SFS do CDA 4 com 20 feições em cada nó

Das variáveis selecionadas pelo experimento do CDA 4, em média 63% são de natureza espectral e 37% de natureza espacial, apresentando um acréscimo ainda maior quanto à seleção das variáveis espaciais em relação aos CDA 1, 2 e 3. Neste conjunto de experimentos este é o CDA que mais utilizou variáveis espaciais.

A avaliação da acurácia deste experimento seguiu o mesmo padrão apresentado anteriormente (*hold-out*). Como em todos os experimentos com LV de 80% verifica-se que os erros envolvidos nesse CDA dizem respeito principalmente à confusão entre as classes telhado de cerâmica (3) e solo exposto (6), onde a maioria dos objetos que deveriam ser classificados na classe 3 foram classificados na classe 1, resultando em uma acurácia extremamente baixa para as classes 3 e 6.

A acurácia geral estimada para o experimento CDA 4 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 64%, um pouco inferior ao CDA 3, inferindo a possibilidade da visualização do efeito de *Hughes*. A acurácia do usuário manteve-se superior à acurácia do produtor, como nos demais experimentos, com comportamento quantitativamente similar. A tabela de contingência, apresentando os erros e acurácias envolvidos está apresenta na Tabela 11.

Tabela 11 – Tabela de Contingência do CDA 4

Tabela de Contingência										
CDA 4										
Limiar de Verossimilhança 80%										
20 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	90,48%	63	0	57	0	0	4	0	2
Telhado Cerâmica	3	0,00%	79	74	5	0	0	0	0	0
Vegetação Arbórea	4	100,00%	84	0	0	0	84	0	0	0
Vegetação Rasteira	5	95,19%	104	3	1	0	1	99	0	0
Solo Exposto	6	0,00%	69	65	2	0	0	0	0	2
Vias	7	96,83%	63	1	0	0	0	1	0	61
Total de Amostras Classificadas na Classe			555	235	66	0	85	104	0	65
Acurácia (%) **				39,15%	96,36%	0,00%	98,82%	95,19%	0,00%	93,85%
Índice Kappa			65,41%							
Acurácia Média do Usuário			68,77%							
Acurácia Média do Produtor			59,05%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

Neste conjunto de experimentos, relacionando todos os CDA 1, 2, 3 e 4, algumas considerações podem ser relevantes:

- O experimento com maior número de nós é o CDA 1;

- Nos nós contendo apenas as classes Telhado Cerâmica (classe 3) e Solo Exposto (classe 6), são selecionados essencialmente atributos espaciais;
- Há presença significativa de erros de inclusão, principalmente na classe 1, onde os objetos que deveriam ser classificados nas classes 3 e 6, foram classificados na classe 1;
- A acurácia geral estimada para as classes 3 e 6 são sempre extremamente baixas, próximo a zero.

Para visualização das acurácias do CDA em todos experimentos com LV de 80%, apresenta-se um gráfico resumo, na Figura 43, contendo as acurácias média do usuário, do classificador e o índice *kappa*. A relação com a identificação do experimento pode ser feita pelo número de feições apresentado no eixo horizontal.




Figura 43 – Gráfico de acurácias do primeiro conjunto de experimentos do CDA

As acurácias do usuário e do classificador das classes, deste conjunto de experimentos, estão apresentadas nos gráficos resumos, na Figura 44 e 45, respectivamente.




Figura 44 – Gráfico de acurácias do usuário para o primeiro conjunto de experimentos do CDA




Figura 45 – Gráfico de acurácias do produtor para o primeiro conjunto de experimentos do CDA

4.8.4. Experimento com Limiar de Verossimilhança de 90%

O segundo conjunto de experimentos foi realizado como os experimentos apresentados no capítulo 4.8.3, manteve-se um LV fixo, neste caso de 90%, e aplicou-se um incremento quanto ao número de variáveis por nó, avaliando o comportamento da árvore, das classes e variáveis selecionadas e a acurácia da classificação.

O experimento ilustrado na Figura 46 e na Figura 47 (CDA 5) utiliza 5 feições em cada nó e apresenta uma estrutura com 21 nós, sendo destes, 11 nós terminais. A Figura 46 apresenta o conjunto de classes em cada nó, sendo o par de classes com maior separação apresentados pela cor em destaque. A Figura 47 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.

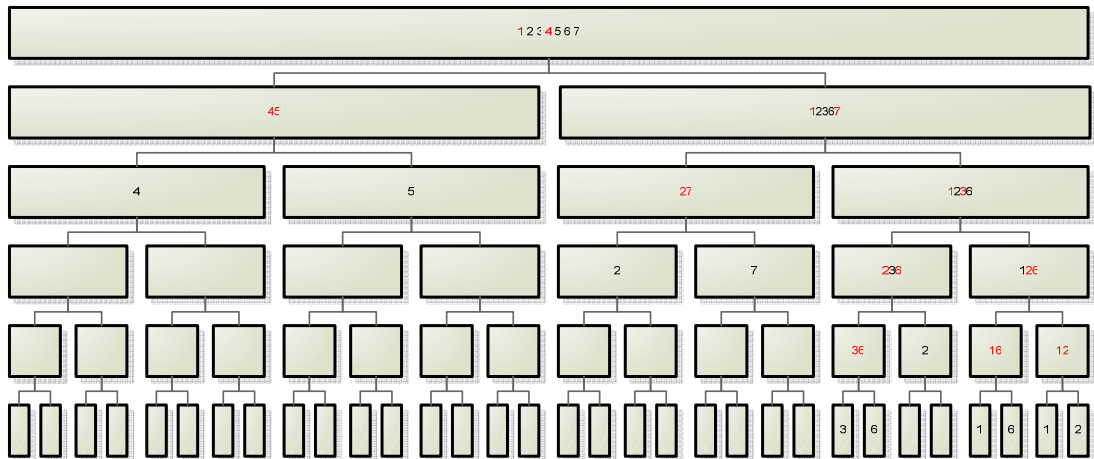


Figura 46 – CDA 5: LV de 90% e 5 feições em cada nó




Figura 47 – Variáveis definidas via SFS do CDA 5 com 5 feições em cada nó

Das variáveis selecionadas pelo experimento do CDA 5, em média 85% são de natureza espectral e 15% de natureza espacial. As variáveis espaciais estão dispostas somente nos nós **n6** (classes 2 e 7) e **n28** (classes 3 e 6), sendo que em **n6** somente atributos espaciais foram selecionados como mais representativos para o par de classes.

Para estimação da acurácia do CDA 5 classificaram-se as amostras de testes das classes (método de estimação: *hold-out*). Os erros envolvidos nessa árvore dizem respeito principalmente à confusão entre as classes telhado de cerâmica (3) e solo exposto (6), onde a maioria dos objetos que deveriam ser classificados na classe 3 foram classificados na classe 6, contudo, neste experimento não houve confusão com a classe telhado claro (1), como nos apresentados com LV de 80%, resultando em uma acurácia extremamente baixa somente para a classe 3.

A acurácia geral estimada para o experimento CDA 5 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 78%, consideravelmente superior aos experimentos com LV de 80%. A acurácia do usuário para a grande maioria das classes foi superior a acurácia do produtor, de uma forma mais visível para o caso da classe 6, indicando a ocorrência de um número maior de erros de inclusão do que de omissão. A tabela de contingência, apresentando os erros e acurácias envolvidos está apresenta na Tabela 12.

Tabela 12 – Tabela de Contingência do CDA 5

Tabela de Contingência										
CDA 5										
Limiar de Verossimilhança 90%										
5 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	92,06%	63	1	58	0	0	4	0	0
Telhado Cerâmica	3	0,00%	79	0	3	0	0	1	75	0
Vegetação Arbórea	4	97,62%	84	0	0	0	82	2	0	0
Vegetação Rasteira	5	94,23%	104	1	0	0	2	98	3	0
Solo Exposto	6	98,55%	69	0	0	0	0	1	68	0
Vias	7	90,48%	63	0	6	0	0	0	0	57
Total de Amostras Classificadas na Classe			555	94	68	0	84	106	146	57
Acurácia (%) **				97,87%	85,29%	0,00%	97,62%	92,45%	46,58%	100,00%
Índice Kappa			78,92%							
Acurácia Média do Usuário			81,69%							
Acurácia Média do Produtor			74,26%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

O experimento ilustrado na Figura 48 e na Figura 49 (CDA 6) utiliza 10 feições em cada nó e apresenta uma estrutura com 19 nós, sendo destes, 10 nós terminais. A Figura 48 apresenta o conjunto de classes de cada nó, sendo o par de classes com maior separação apresentado pela cor em destaque. A Figura 49 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.




Figura 48 – CDA 6: LV de 90% e 10 feições em cada nó




Figura 49 – Variáveis definidas via SFS do CDA 6 com 10 feições em cada nó

Das variáveis selecionadas pelo experimento do CDA 6, em média 85% são de natureza espectral e 15% de natureza espacial, sendo que 44% das variáveis espaciais do CDA 6 estão dispostas em **n28** (classes 3 e 6), representando 70% das variáveis do nó.

A avaliação da acurácia deste experimento seguiu o mesmo padrão apresentado (*hold out*), fazendo uso de um conjunto de amostras de testes. Como para o CDA 5, os erros envolvidos neste experimento dizem respeito principalmente à confusão entre as classes telhado de cerâmica (3) e solo exposto (6), onde a maioria dos objetos que deveriam ser classificados na classe 3 foram classificados na classe 6, resultando em uma acurácia extremamente baixa para a classe 3. Neste experimento, também não esteve apresentada confusão entres as classes 3 e 6 com a classe 1.

A acurácia geral estimada para o experimento CDA 6 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 80%, superior aos demais experimentos até então apresentados. A acurácia do usuário para a grande maioria das classes manteve-se superior a acurácia do produtor, sendo que o principal erro de inclusão foi para o caso da classe 6 e o de omissão para o caso da classe 3. A tabela de contingência, apresentando os erros e acurácias envolvidos está apresenta na Tabela 13.

Tabela 13 – Tabela de Contingência do CDA 6

Tabela de Contingência										
CDA 6										
Limiar de Verossimilhança 90%										
10 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	98,41%	63	0	62	0	0	1	0	0
Telhado Cerâmica	3	0,00%	79	0	3	0	0	0	76	0
Vegetação Arbórea	4	100,00%	84	0	0	0	84	0	0	0
Vegetação Rasteira	5	96,15%	104	1	1	0	0	100	2	0
Solo Exposto	6	98,55%	69	0	0	0	0	0	68	1
Vias	7	92,06%	63	0	5	0	0	0	0	58
Total de Amostras Classificadas na Classe			555	93	72	0	84	101	146	59
Acurácia (%) **				98,92%	86,11%	0,00%	100,00%	99,01%	46,58%	98,31%
Índice Kappa			80,83%							
Acurácia Média do Usuário			83,44%							
Acurácia Média do Produtor			75,56%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

O experimento apresentado na Figura 50 e na Figura 51 (CDA 7) utiliza 15 feições em cada nó e apresenta uma estrutura com 19 nós, sendo destes, 10 nós terminais. A Figura 50 apresenta o conjunto de classes de cada nó, sendo o par de classes com maior separação apresentado pela cor em destaque. A Figura 51 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.




Figura 50 – CDA 7: LV de 90% e 15 feições em cada nó




Figura 51 – Variáveis definidas via SFS do CDA 7 com 15 feições em cada nó

Das variáveis selecionadas pelo experimento do CDA 7, em média 73% são de natureza espectral e 27% de natureza espacial, sendo que o nó com maior representação de variáveis espaciais continua sendo o **n28** (classes 3 e 6). Houve um acréscimo em 12% de utilização das variáveis espaciais em comparação aos CDA 5 e 6.

A avaliação da acurácia desta árvore seguiu o mesmo padrão apresentado anteriormente (*hold-out*). Neste conjunto de experimentos verifica-se que os erros envolvidos neste experimento dizem respeito principalmente à confusão entre as classes telhado de cerâmica (3) e solo exposto (6), onde a maioria dos objetos que deveriam ser classificados na classe 3 foram classificados na classe 6, resultando em uma acurácia extremamente baixa para a classe 3. Neste experimento, também não esteve apresentada confusão entres as classes 3 e 6 com a classe 1.

A acurácia geral estimada para o experimento CDA 7 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 80%. A acurácia do usuário para a grande maioria das classes manteve-se superior à acurácia do produtor. A tabela de contingência, apresentando os erros e acurácias envolvidos está apresenta na Tabela 14.

Tabela 14 – Tabela de Contingência do CDA 7

Tabela de Contingência										
CDA 7										
Limiar de Verossimilhança 90%										
15 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	92,06%	63	0	58	0	0	3	0	2
Telhado Cerâmica	3	0,00%	79	0	3	0	0	0	76	0
Vegetação Arbórea	4	98,81%	84	0	0	0	83	1	0	0
Vegetação Rasteira	5	96,15%	104	2	1	0	0	100	1	0
Solo Exposto	6	98,55%	69	0	0	0	0	0	68	1
Vias	7	98,41%	63	1	0	0	0	0	0	62
Total de Amostras Classificadas na Classe			555	95	63	0	83	104	145	65
Acurácia (%) **				96,84%	92,06%	0,00%	100,00%	96,15%	46,90%	95,38%
Índice Kappa			80,61%							
Acurácia Média do Usuário			83,27%							
Acurácia Média do Produtor			75,33%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

O experimento ilustrado na Figura 52 e na Figura 53 (CDA 8) utiliza 20 feições em cada nó e apresenta uma estrutura similar aos CDA 6 e 7, com 19 nós, sendo destes, 10 nós terminais. A Figura 52 apresenta o conjunto de classes de cada nó, sendo o par de classes com maior separação apresentado pela cor em destaque. A Figura 53 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.




Figura 52 – CDA 8: LV de 90% e 20 feições em cada nó




Figura 53 – Variáveis definidas via SFS do CDA 8 com 20 feições em cada nó

Das variáveis selecionadas pelo experimento do CDA 8, em média 63% são de natureza espectral e 37% de natureza espacial, apresentando um acréscimo ainda maior quanto à seleção das variáveis espaciais em relação aos CDA 5, 6 e 7. Neste conjunto de experimentos este é o CDA que mais utilizou variáveis espaciais.

A avaliação da acurácia deste experimento seguiu o mesmo padrão apresentado anteriormente (*hold-out*). Como em todos os experimentos com LV de 90% verifica-se que os erros envolvidos nesse CDA dizem respeito principalmente à confusão entre as classes telhado de cerâmica (3) e solo exposto (6), onde a maioria dos objetos que deveriam ser classificados na classe 3 foram classificados na classe 6, resultando em uma acurácia extremamente baixa para a classe 3.

A acurácia geral estimada para o experimento CDA 8 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 79%, um pouco inferior ao CDA 6 e 7, inferindo a possibilidade da visualização do efeito de *Hughes*. A acurácia do usuário manteve-se superior à acurácia do produtor, como nos demais experimentos, com comportamento quantitativamente similar. A tabela de contingência, apresentando os erros e acurácias envolvidos está presente na Tabela 15.

Tabela 15 – Tabela de Contingência do CDA 8

Tabela de Contingência										
CDA 8										
Limiar de Verossimilhança 90%										
20 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	90,48%	63	0	57	0	0	4	0	2
Telhado Cerâmica	3	0,00%	79	0	3	0	0	0	76	0
Vegetação Arbórea	4	100,00%	84	0	0	0	84	0	0	0
Vegetação Rasteira	5	95,19%	104	2	1	0	1	99	1	0
Solo Exposto	6	97,10%	69	0	0	0	0	0	67	2
Vias	7	96,83%	63	1	0	0	0	1	0	61
Total de Amostras Classificadas na Classe			555	95	62	0	85	104	144	65
Acurácia (%) **				96,84%	91,94%	0,00%	98,82%	95,19%	46,53%	93,85%
Índice Kappa			79,98%							
Acurácia Média do Usuário			82,65%							
Acurácia Média do Produtor			74,74%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

Neste conjunto de experimentos, relacionando os CDA 5, 6, 7 e 8, algumas considerações podem ser relevantes:

- O experimento com maior número de nós é o CDA 5;
- Nos nós contendo apenas as classes Telhado Cerâmica (classe 3) e Solo Exposto (classe 6), são selecionados essencialmente atributos espaciais;
- Há presença significativa de erros de inclusão, principalmente no caso da classe 6, onde os objetos que deveriam ser classificados nas classes 3, foram classificados na classe 6;
- A acurácia geral estimada para a classe 3 é sempre extremamente baixas, próximo a zero.

Para visualização das acurácias do CDA em todos os experimentos com LV de 90%, apresenta-se um gráfico resumo, na Figura 54, contendo as acurácias média do usuário, do classificador e o índice *kappa*. A relação com a identificação do experimento pode ser feita pelo número de feições apresentado no eixo horizontal.

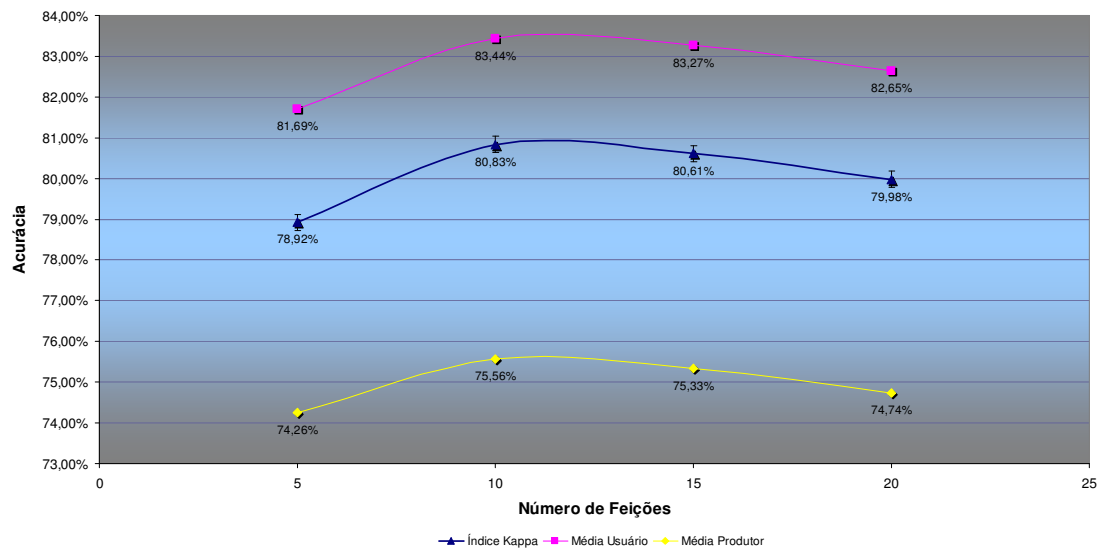


Figura 54 – Gráfico de acurácias do segundo conjunto de experimentos do CDA

As acurácias do usuário e do classificador das classes, deste conjunto de experimentos, estão apresentadas nos gráficos resumos, na Figura 55 e 56, respectivamente.




Figura 55 – Gráfico de acurácias do usuário para o segundo conjunto de experimentos do CDA




Figura 56 – Gráfico de acurácias do produtor para o segundo conjunto de experimentos do CDA

4.8.5. Experimento com Limiar de Verossimilhança de 95%

O terceiro conjunto de experimentos foi realizado como os experimentos apresentados, manteve-se um LV fixo, neste caso de 95%, e aplicou-se um incremento quanto ao número de variáveis por nó, avaliando o comportamento da árvore, das classes e variáveis selecionadas e a acurácia da classificação.

O experimento ilustrado na Figura 57 e na Figura 58 (CDA 5) utiliza 5 feições em cada nó e apresenta uma estrutura com 23 nós, sendo destes, 12 nós terminais. A Figura 57 apresenta o conjunto de classes em cada nó, sendo o par de classes com maior separação apresentados pela cor em destaque. A Figura 58 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.




Figura 57 – CDA 9: LV de 95% e 5 feições em cada nó




Figura 58 – Variáveis definidas via SFS do CDA 9 com 5 feições em cada nó

Das variáveis selecionadas pelo experimento do CDA 9, em média 86% são de natureza espectral e 14% de natureza espacial. As variáveis espaciais estão dispostas somente nos nós **n6** (classes 2 e 7) e **n28** (classes 3 e 6), sendo que em **n6** somente atributos espaciais foram selecionados como mais representativos para o par de classes.

Para estimação da acurácia do CDA 9 classificaram-se as amostras de testes das classes (método de estimação: *hold-out*). Os erros envolvidos nessa árvore dizem respeito principalmente à confusão entre as classes telhado de cerâmica (3) e solo

exposto (6), onde a maioria dos objetos que deveriam ser classificados na classe 3 foram classificados na classe 6, resultando em uma acurácia extremamente baixa somente para a classes 3.

A acurácia geral estimada para o experimento CDA 9 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 79%, superior aos experimentos com LV de 80% e próximo aos experimentos com LV de 90%. A acurácia do usuário para a grande maioria das classes foi superior a acurácia do produtor, de uma forma mais visível para o caso da classe 6, indicando a ocorrência de um número maior de erros de inclusão do que de omissão. A tabela de contingência, apresentando os erros e acurácias envolvidos está apresenta na Tabela 16.

Tabela 16 – Tabela de Contingência do CDA 9

Tabela de Contingência										
CDA 9										
Limiar de Verossimilhança 95%										
5 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	96,83%	63	1	61	0	0	1	0	0
Telhado Cerâmica	3	0,00%	79	0	3	0	0	1	75	0
Vegetação Arbórea	4	97,62%	84	0	0	0	82	2	0	0
Vegetação Rasteira	5	94,23%	104	1	0	0	2	98	3	0
Solo Exposto	6	98,55%	69	0	1	0	0	0	68	0
Vias	7	90,48%	63	0	6	0	0	0	0	57
Total de Amostras Classificadas na Classe			555	94	72	0	84	102	146	57
Acurácia (%)**				97,87%	84,72%	0,00%	97,62%	96,08%	46,58%	100,00%
Índice Kappa			79,56%							
Acurácia Média do Usuário			82,38%							
Acurácia Média do Produtor			74,70%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

O experimento ilustrado na Figura 59 e na Figura 60 (CDA 10) utiliza 10 feições em cada nó e apresenta uma estrutura com 23 nós, sendo destes, 12 nós terminais. A Figura 59 apresenta o conjunto de classes de cada nó, sendo o par de classes com maior separação apresentado pela cor em destaque. A Figura 60 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.




Figura 59 – CDA 10: LV de 95% e 10 feições em cada nó




Figura 60 – Variáveis definidas via SFS do CDA 10 com 10 feições em cada nó

Das variáveis selecionadas pelo experimento do CDA 10, em média 81% são de natureza espectral e 19% de natureza espacial, sendo que 62% das variáveis espaciais do CDA 10 estão dispostas em **n6** (classes 2 e 7) e em **n28** (classes 3 e 6).

A avaliação da acurácia deste experimento seguiu o mesmo padrão apresentado (*hold out*), fazendo uso de um conjunto de amostras de testes. Como para o CDA 9, os erros envolvidos neste experimento dizem respeito principalmente à confusão entre as classes telhado de cerâmica (3) e solo exposto (6), onde a maioria dos

objetos que deveriam ser classificados na classe 3 foram classificados na classe 6, resultando em uma acurácia extremamente baixa para a classe 3.

A acurácia geral estimada para o experimento CDA 10 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 80%. O principal erro neste experimento foi de inclusão foi para o caso da classe 6 e o de omissão para o caso da classe 3. A tabela de contingência, apresentando os erros e acurácias envolvidos está apresenta na Tabela 17.

Tabela 17 – Tabela de Contingência do CDA 10

Tabela de Contingência										
CDA 10										
Limiar de Verossimilhança 95%										
10 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	98,41%	63	0	62	0	0	1	0	0
Telhado Cerâmica	3	0,00%	79	0	3	0	0	0	76	0
Vegetação Arbórea	4	100,00%	84	0	0	0	84	0	0	0
Vegetação Rasteira	5	96,15%	104	1	1	0	0	100	2	0
Solo Exposto	6	98,55%	69	0	0	0	0	0	68	1
Vias	7	92,06%	63	0	5	0	0	0	0	58
Total de Amostras Classificadas na Classe			555	93	72	0	84	101	146	59
Acurácia (%) **				98,92%	86,11%	0,00%	100,00%	99,01%	46,58%	98,31%
Índice Kappa			80,83%							
Acurácia Média do Usuário			83,44%							
Acurácia Média do Produtor			75,56%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

O experimento apresentado na Figura 61 e na Figura 62 (CDA 11) utiliza 15 feições em cada nó e apresenta uma estrutura com 19 nós, sendo destes, 10 nós terminais. A Figura 61 apresenta o conjunto de classes de cada nó, sendo o par de classes com maior separação apresentado pela cor em destaque. A Figura 62 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.




Figura 61 – CDA 11: LV de 95% e 15 feições em cada nó




Figura 62 – Variáveis definidas via SFS do CDA 11 com 15 feições em cada nó

Das variáveis selecionadas pelo experimento do CDA 11, em média 74% são de natureza espectral e 26% de natureza espacial, sendo que o nó com maior representação de variáveis espaciais continua sendo o **n28** (classes 3 e 6). Houve um acréscimo em 8% de utilização das variáveis espaciais em comparação aos CDA 10.

A avaliação da acurácia desta árvore seguiu o mesmo padrão apresentado anteriormente (*hold-out*). Neste conjunto de experimentos verifica-se que os erros

envolvidos neste experimento dizem respeito principalmente à confusão entre as classes telhado de cerâmica (3) e solo exposto (6), onde a maioria dos objetos que deveriam ser classificados na classe 3 foram classificados na classe 6, resultando em uma acurácia extremamente baixa para a classe 3.

A acurácia geral estimada para o experimento CDA 11 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 80%. A tabela de contingência, apresentando os erros e acurácias envolvidos está apresenta na Tabela 18.

Tabela 18 – Tabela de Contingência do CDA 11

Tabela de Contingência										
CDA 11										
Limiar de Verossimilhança 95%										
15 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%) [*]	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	92,06%	63	0	58	0	0	3	0	2
Telhado Cerâmica	3	0,00%	79	0	3	0	0	0	76	0
Vegetação Arbórea	4	98,81%	84	0	0	0	83	1	0	0
Vegetação Rasteira	5	96,15%	104	2	1	0	0	100	1	0
Solo Exposto	6	98,55%	69	0	0	0	0	0	68	1
Vias	7	98,41%	63	1	0	0	0	0	0	62
Total de Amostras Classificadas na Classe			555	95	63	0	83	104	145	65
Acurácia (%) ^{**}				96,84%	92,06%	0,00%	100,00%	96,15%	46,90%	95,38%
Índice Kappa			80,61%							
Acurácia Média do Usuário			83,27%							
Acurácia Média do Produtor			75,33%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

O experimento ilustrado na Figura 63 e na Figura 64 (CDA 12) utiliza 20 feições em cada nó e apresenta uma estrutura com 21 nós, sendo destes, 11 nós terminais. A Figura 63 apresenta o conjunto de classes de cada nó, sendo o par de classes com maior separação apresentado pela cor em destaque. A Figura 64 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.




Figura 63 – CDA 12: LV de 95% e 20 feições em cada nó




Figura 64 – Variáveis definidas via SFS do CDA 12 com 20 feições em cada nó

Das variáveis selecionadas pelo experimento do CDA 12, em média 63% são de natureza espectral e 37% de natureza espacial, apresentando um acréscimo ainda maior quanto à seleção das variáveis espaciais em relação aos CDA 9, 10 e 11. Neste conjunto de experimentos este é o CDA que mais utilizou variáveis espaciais.

A avaliação da acurácia deste experimento seguiu o mesmo padrão apresentado anteriormente (*hold-out*). Como em todos os experimentos com LV de 90% e 95% verifica-se que os erros envolvidos nesse CDA dizem respeito principalmente à

confusão entre as classes telhado de cerâmica (3) e solo exposto (6), onde a maioria dos objetos que deveriam ser classificados na classe 3 foram classificados na classe 6, resultando em uma acurácia extremamente baixa para a classe 3.

A acurácia geral estimada para o experimento CDA 12 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 80%, apresentando uma acurácia muito similar para todas as árvores deste conjunto de experimentos. A acurácia do usuário manteve-se ligeiramente superior à acurácia do produtor, como nos demais experimentos. A tabela de contingência, apresentando os erros e acurácias envolvidos está apresenta na Tabela 19.

Tabela 19 – Tabela de Contingência do CDA 12

Tabela de Contingência										
CDA 12										
Limiar de Verossimilhança 95%										
20 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%) [*]	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	96,83%	63	0	61	0	0	0	0	2
Telhado Cerâmica	3	0,00%	79	0	3	0	0	0	76	0
Vegetação Arbórea	4	100,00%	84	0	0	0	84	0	0	0
Vegetação Rasteira	5	95,19%	104	2	1	0	1	99	1	0
Solo Exposto	6	97,10%	69	0	0	0	0	0	67	2
Vias	7	96,83%	63	1	0	0	0	1	0	61
Total de Amostras Classificadas na Classe			555	95	66	0	85	100	144	65
Acurácia (%) **				96,84%	92,42%	0,00%	98,82%	99,00%	46,53%	93,85%
Índice Kappa			80,83%							
Acurácia Média do Usuário			83,55%							
Acurácia Média do Produtor			75,35%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

Neste conjunto de experimentos, relacionando os CDA 9, 10, 11 e 12, algumas considerações podem ser relevantes:

- Os experimentos com maior número de nós são o CDA 9 e 10;
- Nos nós contendo apenas as classes Telhado Cerâmica (classe 3) e Solo Exposto (classe 6), são selecionados essencialmente atributos espaciais;

- Há presença significativa de erros de inclusão, principalmente no caso da classe 6, onde os objetos que deveriam ser classificados nas classes 3, foram classificados na classe 6;
- A acurácia geral estimada para a classes 3 são sempre extremamente baixas, próximo a zero.

Para visualização das acurácias do CDA em todos experimentos com LV de 95%, apresenta-se um gráfico resumo, na Figura 65, contendo as acurácias média do usuário, do classificador e o índice *kappa*. A relação com a identificação do experimento pode ser feita pelo número de feições apresentado no eixo horizontal.




Figura 65 – Gráfico de acurácias do terceiro conjunto de experimentos do CDA

As acurácias do usuário e do classificador das classes, deste conjunto de experimentos, estão apresentadas nos gráficos resumos, na Figura 66 e 67, respectivamente.




Figura 66 – Gráfico de acurácias do usuário para o terceiro conjunto de experimentos do CDA




Figura 67 – Gráfico de acurácias do produtor para o terceiro conjunto de experimentos do CDA

4.8.6. Experimento com Limiar de Verossimilhança de 99%

O quarto e último conjunto de experimentos do CDA foi realizado como os demais, mantendo um LV fixo de 99% e aplicando um incremento quanto ao número de variáveis por nó, avaliando o comportamento da árvore, das classes e variáveis selecionadas e a acurácia da classificação.

O experimento ilustrado na Figura 68 e na Figura 69 (CDA 13) utiliza 5 feições em cada nó e apresenta uma estrutura com 59 nós, sendo destes, 30 nós terminais. A Figura 68 apresenta o conjunto de classes em cada nó, sendo o par de classes com maior separação apresentados pela cor em destaque. A Figura 69 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.

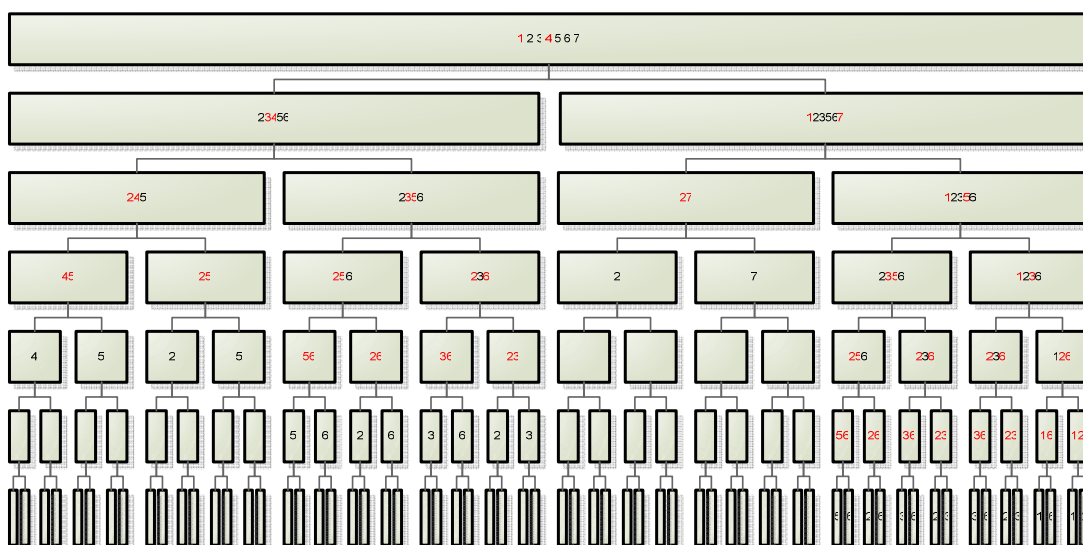


Figura 68 – CDA 13: LV de 99% e 5 feições em cada nó

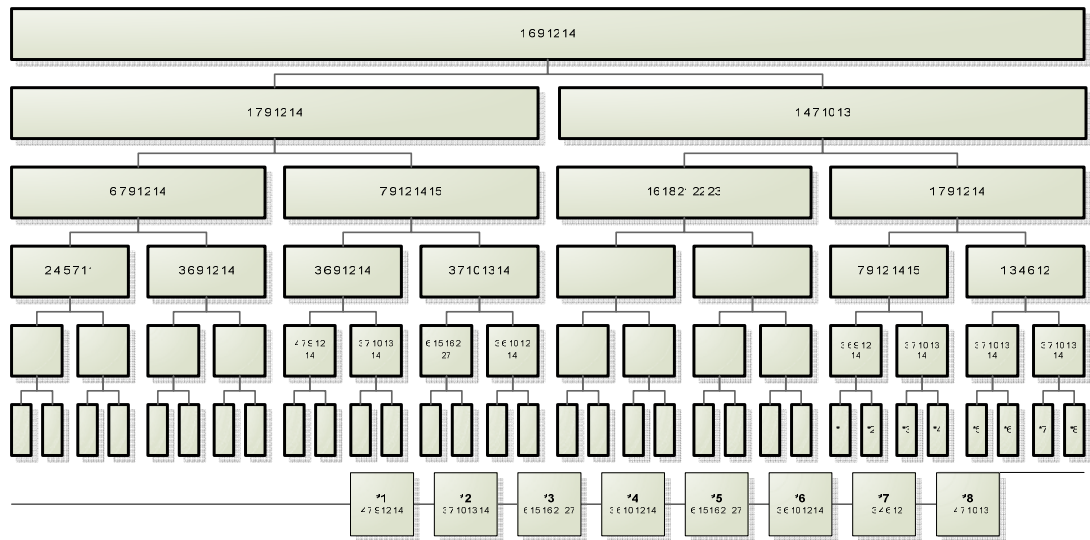


Figura 69 – Variáveis definidas via SFS do CDA 13 com 5 feições em cada nó

Das variáveis selecionadas pelo experimento do CDA 13 em média 89% são de natureza espectral e 11% de natureza espacial. As variáveis espaciais estão dispostas principalmente nos nós **n6** (classes 2 e 7) e **n22**, **n58** e **n60** (classes 3 e 6), sendo que em **n6** somente atributos espaciais foram selecionados como mais representativos para o par de classes.

Para estimação da acurácia do CDA 13 classificaram-se as amostras de testes das classes (método de estimação: *hold-out*). Os erros envolvidos nessa árvore dizem respeito principalmente à confusão entre as classes telhado de cerâmica (3) e solo exposto (6), onde 77% dos objetos que deveriam ser classificados na classe 3 foram classificados na classe 6.

A acurácia geral estimada para o experimento CDA 13 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 86%, superior aos experimentos com LV de 80%, 90% e 95%. A tabela de contingência, apresentando os erros e acurácias envolvidos está apresentada na Tabela 20.

Tabela 20 – Tabela de Contingência do CDA 13

Tabela de Contingência										
CDA 13										
Limiar de Verossimilhança 99%										
5 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	96,83%	63	1	61	0	0	1	0	0
Telhado Cerâmica	3	18,99%	79	0	3	15	0	0	61	0
Vegetação Arbórea	4	97,62%	84	0	0	0	82	2	0	0
Vegetação Rasteira	5	97,12%	104	0	0	0	2	101	1	0
Solo Exposto	6	97,10%	69	0	0	2	0	0	67	0
Vias	7	90,48%	63	0	6	0	0	0	0	57
Total de Amostras Classificadas na Classe			555	93	71	17	84	104	129	57
Acurácia (%) **				98,92%	85,92%	88,24%	97,62%	97,12%	51,94%	100,00%
Índice Kappa			83,13%							
Acurácia Média do Usuário			85,29%							
Acurácia Média do Produtor			88,54%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

O experimento ilustrado na Figura 70 e na Figura 71 (CDA 14) utiliza 10 feições em cada nó e apresenta uma estrutura com 47 nós, sendo destes, 24 nós terminais. A Figura 70 apresenta o conjunto de classes de cada nó, sendo o par de classes com maior separação apresentado pela cor em destaque. A Figura 71 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.




Figura 70 – CDA14: LV de 99% e 10 feições em cada nó

Tabela 21 – Tabela de Contingência do CDA 14

Tabela de Contingência										
CDA 14										
Limiar de Verossimilhança 99%										
10 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	98,41%	63	0	62	0	0	1	0	0
Telhado Cerâmica	3	12,66%	79	0	3	10	0	0	66	0
Vegetação Arbórea	4	100,00%	84	0	0	0	84	0	0	0
Vegetação Rasteira	5	100,00%	104	0	0	0	0	104	0	0
Solo Exposto	6	98,55%	69	0	0	1	0	0	68	0
Vias	7	92,06%	63	0	5	0	0	0	0	58
Total de Amostras Classificadas na Classe			555	92	71	11	84	105	134	58
Acurácia (%) **				100,00%	87,32%	90,91%	100,00%	99,05%	50,75%	100,00%
Índice Kappa				83,77%						
Acurácia Média do Usuário				85,80%						
Acurácia Média do Produtor				89,72%						
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

O experimento apresentado na Figura 72 e na Figura 73 (CDA 15) utiliza 15 feições em cada nó e apresenta uma estrutura com 47 nós, sendo destes, 24 nós terminais. A Figura 72 apresenta o conjunto de classes de cada nó, sendo o par de classes com maior separação apresentado pela cor em destaque. A Figura 73 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.




Figura 72 – CDA 15: LV de 99% e 15 feições em cada nó

Tabela 22 – Tabela de Contingência do CDA 15

Tabela de Contingência										
CDA 15										
Limiar de Verossimilhança 99%										
15 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	100,00%	63	0	63	0	0	0	0	0
Telhado Cerâmica	3	15,19%	79	0	3	12	0	0	64	0
Vegetação Arbórea	4	98,81%	84	0	0	0	83	1	0	0
Vegetação Rasteira	5	100,00%	104	0	0	0	0	104	0	0
Solo Exposto	6	100,00%	69	0	0	0	0	0	69	0
Vias	7	95,24%	63	1	2	0	0	0	0	60
Total de Amostras Classificadas na Classe			555	93	69	12	83	105	133	60
Acurácia (%) **				98,92%	91,30%	100,00%	100,00%	99,05%	51,88%	100,00%
Índice Kappa				84,82%						
Acurácia Média do Usuário				86,88%						
Acurácia Média do Produtor				91,59%						
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

O último experimento do CDA está ilustrado na Figura 74 e na Figura 75 (CDA 16), utiliza 5 feições em cada nó e apresenta uma estrutura com 51 nós, sendo destes, 26 nós terminais. A Figura 74 apresenta o conjunto de classes de cada nó, sendo o par de classes com maior separação apresentado pela cor em destaque. A Figura 75 apresenta o conjunto de atributos selecionados pelo SFS em cada um destes nós.




Figura 74 – CDA 16: LV de 99% e 20 feições em cada nó

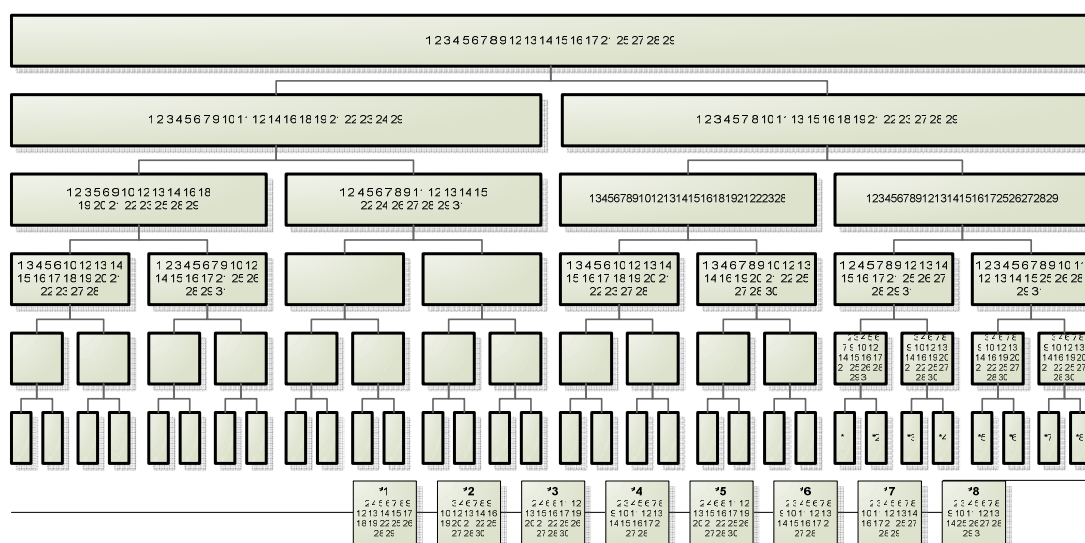


Figura 75 – Variáveis definidas via SFS do CDA 16 com 20 feições em cada nó

Das variáveis selecionadas pelo experimento do CDA 16, em média 63% são de natureza espectral e 37% de natureza espacial, apresentando um acréscimo ainda maior quanto à seleção das variáveis espaciais em relação aos CDA 13, 14 e 15. Em todos os conjuntos de experimentos este é o CDA que mais utilizou variáveis espaciais.

A avaliação da acurácia deste experimento seguiu o mesmo padrão apresentado anteriormente (*hold-out*). Como em todos os experimentos com LV de 90%, 95% e 99%, verifica-se que os erros envolvidos nesse CDA dizem respeito principalmente à confusão entre as classes telhado de cerâmica (3) e solo exposto (6), onde a maioria dos objetos que deveriam ser classificados na classe 3 foram classificados na classe 6.

A acurácia geral estimada para o experimento CDA 16 (índice *kappa*, acurácia média do produtor e acurácia média do usuário) oscilou em torno de 88%, apresentando uma acurácia muito similar para todas as árvores deste conjunto de experimentos. A tabela de contingência, apresentando os erros e acurácias envolvidos está apresentada na Tabela 23.

Tabela 23 – Tabela de Contingência do CDA 16

Tabela de Contingência										
CDA 16										
Limiar de Verossimilhança 99%										
20 Feições por nó										
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias
Telhado Claro	1	98,92%	93	92	1	0	0	0	0	0
Telhado Escuro	2	100,00%	63	0	63	0	0	0	0	0
Telhado Cerâmica	3	18,99%	79	0	3	15	0	0	61	0
Vegetação Arbórea	4	100,00%	84	0	0	0	84	0	0	0
Vegetação Rasteira	5	99,04%	104	0	0	0	1	103	0	0
Solo Exposto	6	100,00%	69	0	0	0	0	0	69	0
Vias	7	95,24%	63	1	2	0	0	0	0	60
Total de Amostras Classificadas na Classe			555	93	69	15	85	103	130	60
Acurácia (%) **				98,92%	91,30%	100,00%	98,82%	100,00%	53,08%	100,00%
Índice Kappa			85,45%							
Acurácia Média do Usuário			87,46%							
Acurácia Média do Produtor			91,73%							
* Erro Percentual de Omissão - Acurácia do Usuário										
** Erro Percentual de Comissão - Acurácia do Produtor										

Neste conjunto de experimentos, relacionando os CDA 13, 14, 15 e 16, algumas considerações podem ser relevantes:

- O experimento com maior número de nós é o CDA 16, com 59 nós;
- A uma tendência de seleção dos atributos espaciais quando há a presença, principalmente das classes 2, 3, 6 e 7;
- O principal fator de erro neste conjunto de experimentos é devido à inclusão de objetos que deveriam ser classificados na classe 3 e foram classificados na classe 6;
- A acurácia do usuário para todas as classes, com exceção da classe 3, foi superior à 95%;
- A acurácia do classificador para todas as classes, com exceção da classe 6, foi superior à 90%.

Para visualização das acurácias do CDA em todos experimentos com LV de 99%, apresenta-se um gráfico resumo, na Figura 76, contendo as acurácias média do

usuário, do classificador e o índice *kappa*. A relação com a identificação do experimento pode ser feita pelo número de feições apresentado no eixo horizontal.

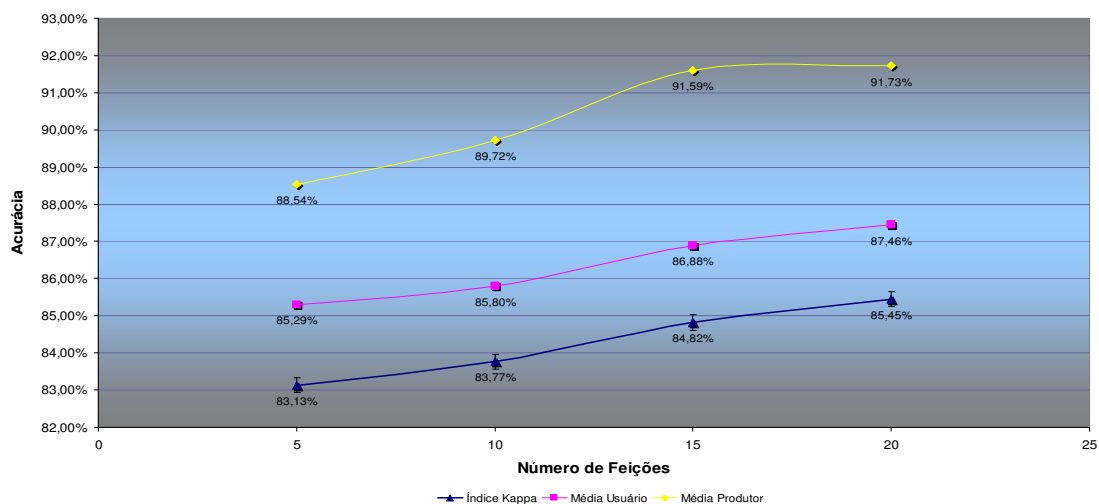


Figura 76 – Gráfico de acurácias do quarto conjunto de experimentos do CDA

As acurácias do usuário e do classificador das classes, deste conjunto de experimentos, estão apresentadas nos gráficos resumos, na Figura 77 e 78, respectivamente.




Figura 77 – Gráfico de acurácias do usuário para o quarto conjunto de experimentos do CDA




Figura 78 – Gráfico de acurácias do produtor para o quarto conjunto de experimentos do CDA

4.8.7. Classificador de Decisão em Árvore x Classificador em Estágio Único

Um conjunto final de experimentos teve por objetivo fazer uma comparação entre o classificador em estágio múltiplo adotado (CDA) e um classificador tradicional em estágio único (CEU), este último utilizando *pixels* individuais como padrões a serem classificados. Nestes experimentos, o classificador em estágio único adotado foi o da Máxima Verossimilhança Gaussiana (MVG).

Para proposta de comparação visual da classificação neste experimento, resolveu-se utilizar todos os dados imagem disponíveis e adotou-se uma única árvore para CDA, a que proporcionou a melhor acurácia dentre os 16 CDA investigados, o CDA 16.

O resultado da classificação no processo do CDA foi exportado para um ambiente *GIS* (*Geographic Information System*), software *ArcGIS*, permitindo através do atributos de identificação do objeto relacioná-lo à sua classe indicada. As Figuras 79 A e B apresentam os resultados da classificação pela CEU e CDA, respectivamente, de

todo os dados imagem disponíveis. As áreas em destaque correspondem às aproximações apresentadas nas figuras seguintes.



Figura 79 – Resultado gráfico do CEU e do CDA

A figura anterior (Figura 79) destaca algumas regiões de referência (Área 1, 2 e 3). A figura a seguir (Figura 80) apresenta uma aproximação visual em referência à

Área 1. A Figura 80 A corresponde aos dados imagem original do sistema *Quickbird* apresentado em cor verdadeira pela composição RGB (3,2,1). A Figura 80 B ao resultado do CEU e a 80 C ao resultado do CDA.

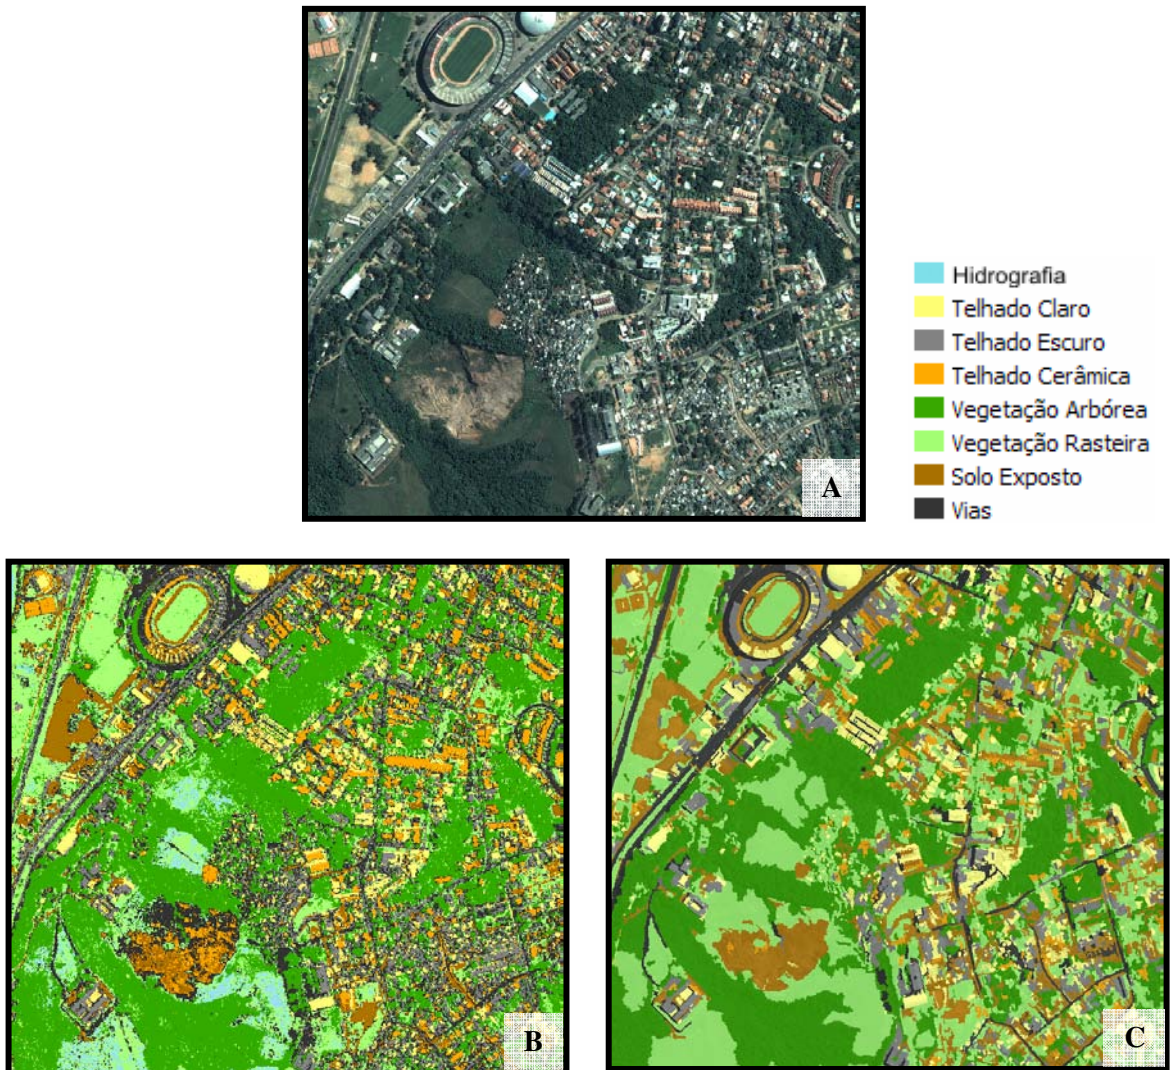


Figura 80 – Resultado gráfico do CEU e do CDA para a Área 1

A Figura 81 apresenta uma aproximação visual em referência à Área 2. A Figura 81 A corresponde aos dados imagem original do sistema *Quickbird* apresentado em cor verdadeira pela composição RGB (3,2,1). A Figura 81 B ao resultado do CEU e a 81 C ao resultado do CDA.

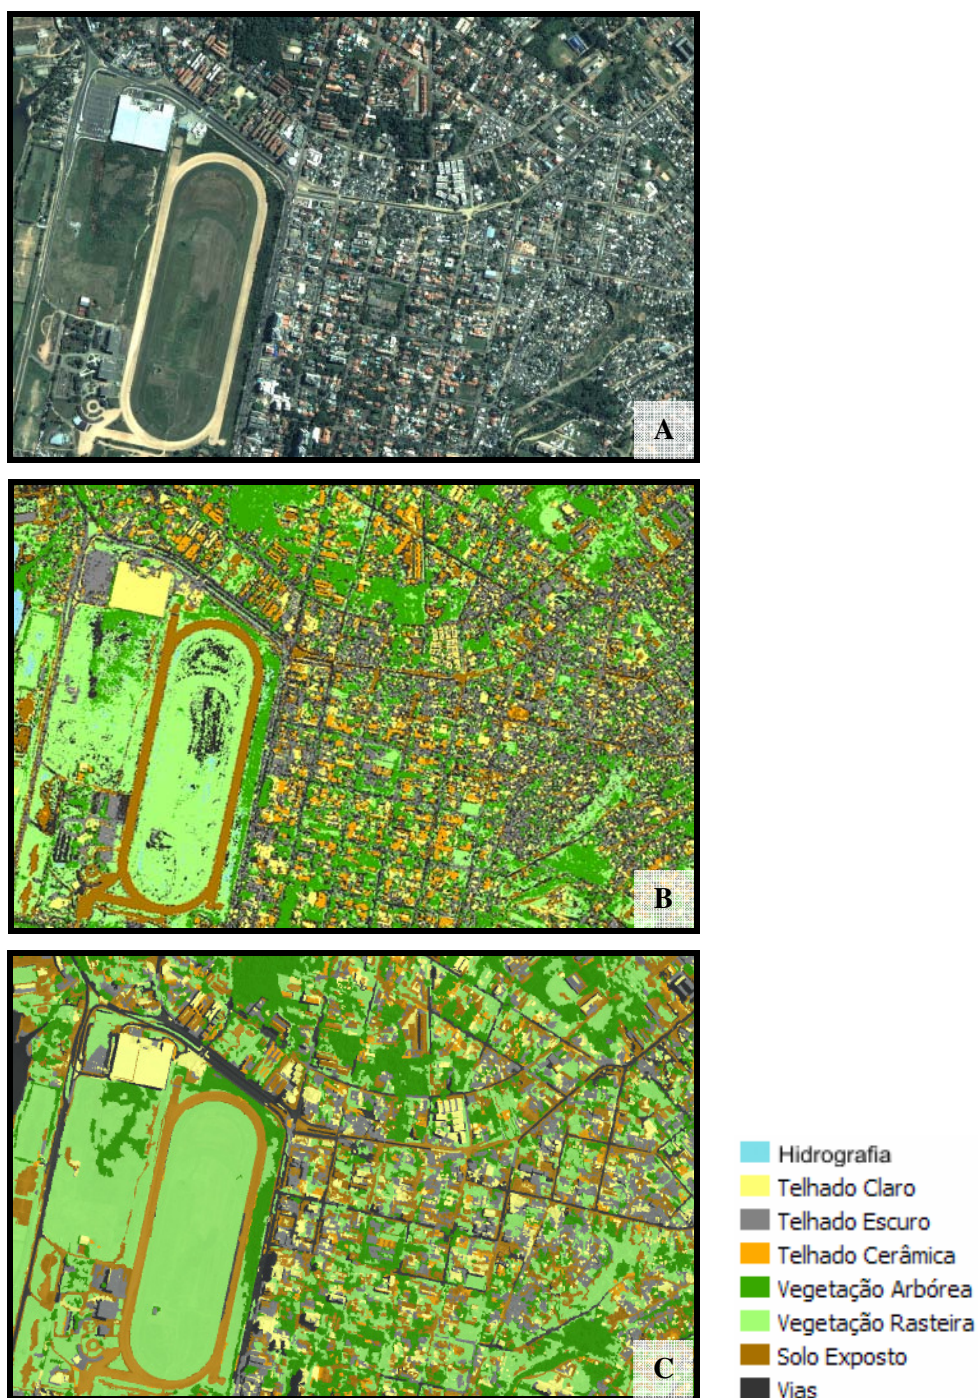


Figura 81 – Resultado gráfico do CEU e do CDA para a Área 2

A Figura 82 apresenta uma aproximação visual em referência à Área 3. A Figura 82 A corresponde aos dados imagem original do sistema *Quickbird* apresentado

em cor verdadeira pela composição RGB (3,2,1). A Figura 82 B ao resultado do CEU e a 82 C ao resultado do CDA.



Figura 82 – Resultado gráfico do CEU e do CDA para a Área 3

A avaliação quantitativa referiu-se a análise da acurácia da classificação. A acurácia do CDA está apresentada na Tabela 23 e a acurácia do CEU, referida na tabela de contingência, estimada pelo método *hold-out*, está apresentada na Tabela 24.

Tabela 24 – Tabela de Contingência do CEU

Tabela de Contingência											
Classificação em Estágio Único											
Função decisão da Máxima Verossimilhança Gaussiana											
Padrão: Pixel											
Nome da Classe	Número da Classe	Acurácia (%)*	Amostras de Teste	1	2	3	4	5	6	7	8
				Telhado Claro	Telhado Escuro	Telhado Cerâmica	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Vias	Hidrografia
Telhado Claro	1	79,14%	8734	6912	1059	0	0	0	213	550	0
Telhado Escuro	2	66,86%	5618	163	3756	8	8	126	39	1515	3
Telhado Cerâmica	3	79,40%	6922	34	21	5496	0	0	219	1152	0
Vegetação Arbórea	4	90,34%	48985	139	56	0	44253	3142	0	1200	195
Vegetação Rasteira	5	80,73%	34308	9	202	0	1350	27696	0	1264	3787
Solo Exposto	6	82,54%	21273	1783	35	1637	0	67	17558	193	0
Vias	7	58,27%	19871	350	6402	99	232	947	258	11578	5
Hidrografia	8	90,83%	28264	2	17	0	84	2401	0	89	25671
Total de Amostras Classificadas na Classe			173975	9392	11548	7240	45927	34379	18287	17541	29661
Acurácia (%) **				73,59%	32,53%	75,91%	96,36%	80,56%	96,01%	66,01%	86,55%
Índice Kappa			70,81%								
Acurácia Média do Usuário			78,51%								
Acurácia Média do Produtor			75,94%								
* Erro Percentual de Omissão - Acurácia do Usuário											
** Erro Percentual de Comissão - Acurácia do Produtor											

Pela análise da Tabela 24, pode-se inferir que os erros envolvidos no CEU não podem ser pontuados conforme os apresentados pelo CDA. Neste caso, não há uma tendência de comportamento (erros de omissão e/ou inclusão) sobre determinadas classes. O que realmente pode-se verificar é a presença de erros de omissão e de inclusão apresentados de modo distribuído. Os principais erros apresentados pelo CEU são de omissão e inclusão quanto às classes telhado (2) escuro e vias (7).

4.8.8. Acurácias (Análise Comparativa)

Verificou-se que, pelas acurácias gerais, o CDA com o maior número de variáveis (20) e com o maior limiar de verossimilhança (99%) encontrou a menor incidência de erros entre todos os experimentos propostos, inclusive em comparação com o classificador em estágio único.

Como o objeto principal da pesquisa visa avaliar a eficiência do CDA com diferentes composições (variáveis e LV), estruturou-se 3 gráficos indicando as acurácias de cada árvore e do CEU. O primeiro gráfico indica a acurácia pelo índice Kappa, o segundo pela acurácia média do usuário e o terceiro pela acurácia média do classificador. O eixo vertical dos gráficos apresenta a acurácia percentual e o eixo horizontal o número de variáveis utilizadas. Como são quatro variáveis (atributos espectrais) utilizadas pelo CEU, representou-se este, nesta posição. Cada conjunto de experimentos está representado em uma linha do gráfico.

A Figura 83 apresenta as medidas de acurácia pelo índice *Kappa* para o CDA e o CEU.




Figura 83 – Gráfico de avaliação da acurácia pelo índice *Kappa* entre todos os experimentos do CDA e o CEU

A Figura 84 apresenta o gráfico das medidas de acurácia média do usuário para o CDA e o CEU.

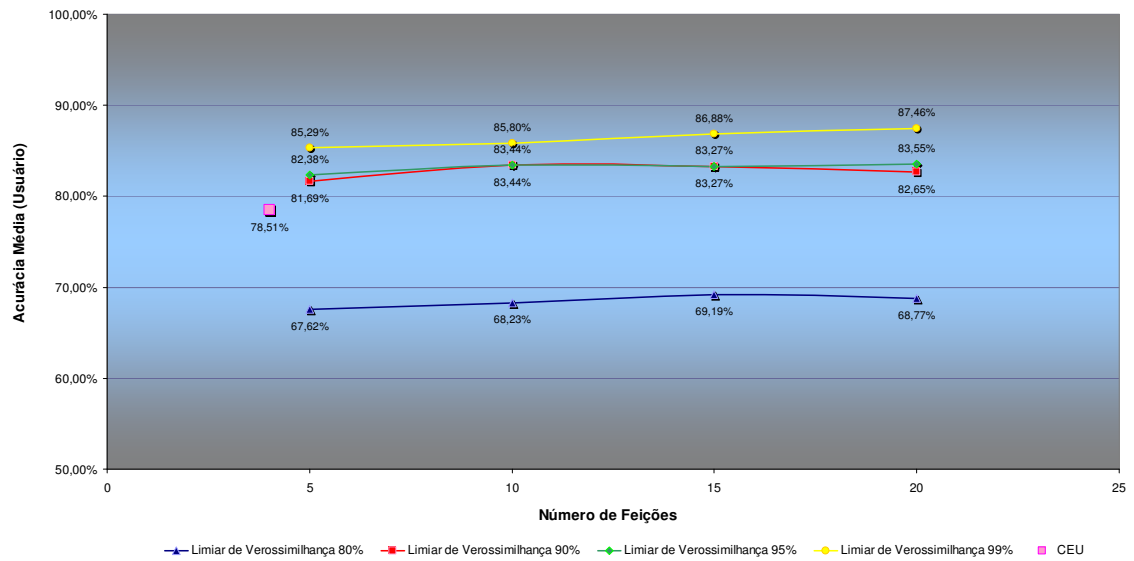


Figura 84 – Gráfico de avaliação da acurácia média do usuário entre todos os experimentos do CDA e o CEU

A Figura 85 apresenta o gráfico das medidas de acurácia média do classificador para o CDA e o CEU.




Figura 85 – Gráfico de avaliação da acurácia média do classificador entre todos os experimentos do CDA e o CEU

CONCLUSÃO

Nesta dissertação foi investigada a utilização de um classificador em estágio múltiplo (CDA), empregando variáveis espectrais e espaciais. Os resultados foram comparados com o processo tradicional que emprega um classificador em estágio único e variáveis espectrais somente (CEU). Os experimentos mostraram um ganho significativo na acurácia das imagens temáticas produzidas pelo método proposto (CDA), com relação ao método tradicional (CEU). A acurácia da classificação pela metodologia proposta atingiu índices aceitáveis e significativamente superiores ao CEU, principalmente quanto maior é a utilização conjunta dos atributos espectrais e espaciais, e nos experimentos com LV de 99%. Para visualização da utilização dos atributos de natureza espectral e espacial, montou-se um gráfico resumo indicando o percentual individual utilizado em cada experimento, apresentado na Figura 86.




Figura 86 – Gráfico de avaliação da utilização conjunta dos atributos espectrais e espaciais entre todos os experimentos do CDA

Os experimentos sugerem que as variáveis espaciais apresentam uma correlação mais alta entre si. Isso pode ser visto sobre as variáveis inicialmente selecionadas no algoritmo SFS em cada nó do CDA, onde um número relativamente baixo de variáveis espaciais é selecionado nos experimentos com 5 e 10 feições por nó, por exemplo. O algoritmo SFS busca selecionar o subconjunto de variáveis que apresentar o maior poder discriminante entre par de classes de informação envolvido, como o SFS seleciona nas primeiras iterações essencialmente atributos espectrais, pode-se inferir que estes que apresentam maior separabilidade, o que não indica um maior poder discriminante para todas as classes de informação envolvidas, visto que a acurácia nestes experimentos é relativamente baixa. A seleção dos atributos espaciais se dá constantemente em menor número, porém quando há maior presença dos atributos espaciais, há também uma maior acurácia da classificação, indicando a alta correlação

entre as variáveis espaciais e ao mesmo tempo um alto poder discriminante dessas variáveis.

Com o aumento do número de feições, para os experimentos de um mesmo LV, não há aumento significativo da acurácia geral (índice *kappa*, acurácia média do produtor e acurácia média do usuário), há um aumento gradual na acurácia, seguindo os efeitos do fenômeno de *Hughes*.

Entretanto, ao aumentar o limiar de verossimilhança, há um aumento expressivo na acurácia geral da classificação. Como o LV representa um fator percentual de verossimilhança entre as classes envolvidas, o par de classes que apresenta maior separabilidade (duas funções decisão) e a classe em teste de verossimilhança (vetor das amostras de treinamento). Um menor valor no LV indica um processo de verossimilhança mais flexível, de modo que a classe em teste sofra mais facilmente o efeito de *pruning* (poda) para os demais nós na árvore. Neste caso, o processo indica que a classe em teste está “pronta” à discriminação para as demais classes, quando isso muitas vezes pode não ser verdade, fazendo com que a acurácia da classificação apresente menores índices.

Um maior valor do LV irá possibilitar que aos nós descendentes somente as classes que forem mais verossímeis sejam unicamente selecionadas, caso contrário, a classe em teste segue para os dois nós descendentes. Nessa proposição, os experimentos encontram os melhores índices de acurácia geral.

Para o conjunto de experimentos com LV de 80%, 90% e 95% a acurácia média do produtor foi ligeiramente menor que a acurácia média do usuário, enquanto que os experimentos com LV de 99% a acurácia média do produtor foi maior que a acurácia do usuário. O que é altamente aceitável, visto que com menores LV há maior probabilidade de erros de omissão.

O CDA no processo orientado a objetos empregando atributos espectrais e espaciais permite na grande maioria das vezes uma maior acurácia na classificação, do que aquela que seria possível com a utilização sobre os processos tradicionalmente

empregados em dados imagem de sensoriamento remoto, como é o caso dos CEUs baseado a *pixels*. Adicionalmente, os CDA permitem a identificação direta dos erros envolvidos sobre as classes, apresentando frequentemente certa tendência, diferente ao CEU, que os erros envolvidos apresentam-se distribuídos de modo não ordenado. A tendência neste caso é altamente positiva, pois pode proporcionar o refinamento e o ajuste dos erros no processo de classificação, além de possibilitar a utilização individual das classes que estão inertes aos erros envolvidos.

A principal desvantagem que o CDA pode apresentar em relação ao CEU está direcionada ao custo computacional. O CDA em qualquer estágio, tanto na construção da árvore, quanto na classificação, apresentam alto custo computacional, devido à alta complexibilidade computacional exigida pelos algoritmos propostos. Como exemplo, pode-se citar que para o processo de classificação dos dados imagens disponíveis (cena de 11,5 km²) foram necessárias mais de 28 horas de processamento utilizando o equipamento apresentado no capítulo 4.1, enquanto que para o CEU a classificação foi realizada em 8 minutos. É válido citar que a implementação do algoritmo foi realizada em ambiente *Matlab*, que apresenta uma eficiência computacional bem menos expressiva que as rotinas disponíveis nos programas comerciais.

Apesar de não estar no escopo de pesquisa, achou-se interessante investigar a capacidade de incorporação dos resultados da classificação num ambiente SIG (Sistemas de Informações Geográfica) através do software *ArcGIS*, realizando o processo inverso ao da seleção de amostras, executado na fase inicial dos experimentos. A interoperacionabilidade encontrada não apresentou qualquer deficiência em ambos os processos de comunicação (importação e exportação), permitindo realizar todos os relacionamentos necessários, mantendo constantemente o formato original das informações, de modo que a integração Sensoriamento Remoto x SIG seja compreendida.

Como sugestão para trabalhos futuros, pode-se mencionar a utilização de métodos de segmentação *top-down* que levem em consideração essencialmente os

elementos das classes envolvidas. Outra proposta é quanto à utilização de atributos no CDA, ao invés de utilizar as variáveis “naturais”, investigar o ganho que pode ser fornecido pelas variáveis resultantes de combinações lineares das variáveis originais, por exemplo, as que otimizem a distância de *Bhattacharyya* para o par de classes em consideração. Devido à possibilidade de aumento da acurácia da classificação apresentado pela metodologia do CDA, sugere-se que os dados imagem de alta resolução espacial sejam submetidos em conjunto a esta metodologia, fornecendo alternativas sustentáveis aos principais problemas inerentes ao CEU em dados imagem de alta resolução espacial.



REFERÊNCIAS BIBLIOGRÁFICAS

BAATZ, M. & SCHAPE, A. “**Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation**”. AGIT-Symposium Salzburg. Karlsruhe, 1999.

BARRET, E. C. & CURTIS, L. F. **Introduction to Environmental Remote Sensing**. Chapman & Hall, London, 1992.

BLASCHKE, T., LANG, S., LORUP, E., STROBL, J. & ZEIL, P. “**Objected oriented image processing in an integrated GIS / remote sensing environment and perspectives for environmental application**”, In environmental Information for Planning, vol. 2, Metropolis-Verlag, 2000.

BOOGAART, K.G.. “**Statistics for Individual Orientation Measurements**”, Graduate College - Spatial Statistics, University of Mining and Technology Freiberg, 1999.

BOW, S. T. **Pattern Recognition and Image Preprocessing**. Marcel Dekker, 1992.

BREIMAN, L., FRIEDMAN, J. H., OLSHEN, R. A., & STONE, R. A. **Classification and Regression Trees (CART)**. Wadsworth Int., Belmont, 1984.

CAMPBELL, J.B. **Introduction to Remote Sensing**. Guilford, Nova Iorque, 1996.

CHICA-OLMO, M. & ABARCA-HERNÁNDEZ, F. “**Computing geostatistical image texture for remotely sensed data classification**”, Computers & Geosciences, vol. 26, pp. 373-383, 2000.

CRESSIE, N. A. C. **Statistics for spatial data revised edition**. Wiley - Interscience publication, cap. 7.4, pp. 499-534, 1993.

DAWSON, B. R. & PARSONS, A. J. “**Texture measures for the identification and monitoring of urban derelict land**”, *International Journal of Remote Sensing*, vol.15, pp. 1259-1271, 1994.

DELLAPOS, A. F. & GAMBA, A. “**Texture-based characterization of urban environments on satellite SAR images**”. *IEEE Trans. on Geoscience and Remote Sensing.*, vol. 41, no. 1, pp. 153-159, 2003.

ECOGNITION. **User’s Guide**. Definiens Imaging. Muchen, Germany, 2003.

FUKUNAGA, K. **Introduction to Statistical Pattern Recognition**. Ed. Boston: Academic Press, 2nd edition, 1990.

GONZALEZ, R. C & WOODS, R. **Digital Image Processing**. Addison-Wesley Publishing. Massachusetts, 2nd edition, 1993.

HARALICK, R. M., SHANMUGAM, K. & DINSTEN, I. “**Textural features for image classification**”, *IEEE Trans. on Systems, Man, and Cybernetics*, vol. SMC-3, no. 6, pp. 610-621, 1973.

HARALICK, R. M. “**Statistical and structural approach to texture**”, *Proceedings of the IEEE*, vol. 67, no. 5, pp. 786-803, 1979.

HE, D. C., WANG, L. & GUIBERT, J. “**Texture discrimination based on an optimal utilization of texture features**”, *Pattern Recognition*, vol. 2, pp. 141-146, 1987.

HUGHES, G. F. “**On the mean accuracy of statistical pattern recognizers**”, *IEEE Trans. on Information Theory*, vol. IT-14, pp. 55– 63, 1968.

KOUSKOULAS, Y., ULABY, F. T. & PIERCE, L. E. “**The Bayesian Hierarchical Classifier (BHC) and its application to short vegetation using multifrequency polarimetric SAR**”, *IEEE Trans. on Geoscience and Remote Sensing*, vol. 42, no. 2, pp. 153-159, 2004.

KURZYNKI, M.W. “**The optimal strategy of a tree classifier**”, *Pattern Recognition Letter*, vol. 1, pp. 305-310, 1983.

LANDEWEERD, G., TIMMERS, T., GERSEMA, E., BINS, M. & HALIC, M. “**Binary tree versus single level tree classification of white blood cells**”, *Pattern Recognition*, vol. 16, pp. 571-577, 1983.

MELGANI, F. “**Contextual reconstruction of cloud-contaminated multitemporal multispectral images**”, *IEEE Trans. on Geoscience and Remote Sensing*, vol. 44, no. 2, pp. 442-455, 2006.

-
- MOIGNE, J. L. & TILTON, J. C. “**Refining Image Segmentation by Integration of Edge and Region Data**”, IEEE Trans. on Geoscience and Remote Sensing, vol. 33, no.3, 1995.
- MUELLER, M., SEGL, K. & KAUFMANN, H. “**Edge- and region-based segmentation technique for the extract of large, man-made objects in high-resolution satellite imagery**”, Pattern Recognition, vol. 37, p.1619-1628, 2004.
- MYINT, S. W. & LAM, N. “**A study of lacunarity-based texture analysis approaches to improve urban image classification**”, Computers, Environment and Urban Systems, vol. 29, pp. 501–523, 2005.
- OLSEN, E. R., RAMSEY, R. D. & WINN, D. S. “**A modified fractal dimension as a measure of landscape diversity**”, Photogrammetric Engineering and Remote Sensing, v. 59, no. 10, p. 1517-1520., 1993.
- PAVULURI, M. K., RAMANATHAN, S., & DANIEL, Z. “**A rule-based classifier using classification and regression tree (CART) approach for urban landscape dynamics**”, International Geoscience and Remote Sensing Symposium, vol. 2, pp. 24–28, 2002.
- QUINLAN, J. R. “**Decision Trees and Decisionmaking**”, IEEE Trans. Systems, Man and Cybernetics, vol. 20, no. 2, pp. 339-346, 1990.
- RICHARDS, J. A & JIA, X. **Remote Sensing Digital Image Analysis**. Springer, 3rd edition, Canberra, 1998.
- ROKACH, L. & MAIMON, O. “**Top-Down Induction of Decision Trees Classifiers - A Survey**”, IEEE Trans. Systems, Man and Cybernetics - Part C: Applications And Reviews, vol. 35, no. 4, pp. 476-487, 2005.
- ROUNDS, E. “**A combined non-parametric approach to feature selection and binary decision tree design**”. Pattern Recognition, vol. 12, pp. 313-317, 1980.
- RYHERD, S. & WOODCOCK, C. “**Combining spectral and texture data in the segmentation of remotely sensed images**”, Photogrammetric Engineering & Remote Sensing, vol. 62, no.2, pp. 181- 194, 1996.
- SAFAVIAN, S. R. & LANDGREBE, D. “**A Survey of Decision Tree Methodology**”, IEEE Trans. Systems, Man and Cybernetics, vol. 21, no. 3, 1991.
- SALI, E. & WOLFSON, H. “**Texture classification in aerial photographs and satellite data**”, International Journal of Remote Sensing, vol. 13, no. 18, pp. 3395-3408, 1992.

SCHOWENGERDT, R. A. **Remote Sensing, Models and Methods for Image Processing**. Academic Press, 2nd edition, Tucson, 1997.

SETHI, I. K. & SARVARAYUDU, G. “**Hierarchical classifier design using mutual information**”, IEEE Trans. on Pattern Analysis and Machine Intelligence, vol. 4, no. 4, pp. 441-445, 1982.

SIMARD, M., SAATCHI, S. S., & GRANDI, G. D. “**The use of decision tree and multiscale texture for classification of JERS-1 SAR data over tropical forest**”, IEEE Trans. on Geoscience and Remote Sensing, vol. 38, no. 5, pp. 2310–2321, 2000.

SWAIN, P. H. & DAVIS, S. M. **Remote Sensing: The Quantitative Approach**. McGraw-Hill. New York, 1978.

TABB, M. & AHUJA, N. “**Multiscale Image Segmentation by Integrated Edge and Region Detection**”, IEEE Trans. on Image Processing, vol. 6, no. 5, pp. 642-654, 1997.

VENDRIG, J. “**Filter Image Browsing: a Study to Image Retrieval in Large Pictorial Databases**”, Department of Intelligent Sensoric Information Systems. Faculty Wins, Amsterdam, 1997.

WESZKA, J. S., DYER, C. R. & ROSENFELD, A. “**A comparative study of texture measures for terrain classification**”. IEEE Trans. Systems, Man and Cybernetics, vol. smc-6, no. 4, pp. 269-285, 1976.

WU, C., LANDGREBE, D. A. & SWAIN, P. “**The decision tree approach to classification**” Purdue University, W. Falayette, REP. RE-EE 75-17, 1975.

ZHANG, D. & LU, G. “**Review of shape representation and description techniques**”, Pattern Recognition, vol. 37, pp. 1-19, 2004.

ANEXO

1

CARACTERÍSTICAS TÉCNICAS DO SISTEMA *QUICKBIRD*

Altitude da órbita	450 km
Inclinação da órbita – linha do equador	97.2°
Sentido da órbita	Descendente 10:30 a.m.
Duração da órbita	93.5 min
Tempo de revisita	1 – 3.5 dias (dependendo da latitude)
Largura nominal da faixa imageada	16.5 km (nadir) 20.8 km (<i>off</i> -nadir)
Resolução espacial (nominal)	0.61 m (nadir) – pancromática 2.44 m (nadir) – multiespectral 0.72 m (<i>off</i> -nadir) – pancromática 2.88 m (<i>off</i> -nadir) – multiespectral
Resolução espectral	Pancromático: 0.45 – 0.90 μm Banda 1: 0.45 – 0.52 μm Banda 2: 0.52 – 0.60 μm Banda 3: 0.63 – 0.69 μm Banda 4: 0.76 – 0.90 μm
Resolução radiométrica	11 bits (2048 níveis de cinza)
Precisão métrica	23 m CE, 17 m erro linear
Agilidade da astronave no percurso (tempo necessário para redirecionar e estabilizar a aquisição de dados)	Manobra de 10° em 20s Manobra de 50° em 45s
Precisão de apontamento	< 5 mRad por eixo
Instrução de apontamento	< 15 μRad por eixo
Estabilidade de apontamento	< 10 μRad por segundo
Capacidade de armazenamento de dados	~ 128 GBits (~56 cenas)
Massa do satélite	1018 kg
Capacidade do satélite	563 W
Tempo de vida útil previsto	> 5 anos

Fonte: Adaptado de *Digital Globe* (acesso em www.digitalglobe.com, junho de 2005)

ANEXO

2

**DADOS IMAGEM DO SISTEMA
QUICKBIRD NO FORMATO
MULTIESPECTRAL**



**DADOS IMAGEM DO SISTEMA
QUICKBIRD NO FORMATO
PANCROMÁTICO**



ANEXO

4


**DADOS IMAGEM DO SISTEMA
QUICKBIRD NO FORMATO
HÍBRIDO**




ANEXO

5


**HISTOGRAMAS DOS DADOS
IMAGEM DO SISTEMA *QUICKBIRD***

ATRIBUTOS ESPECTRAIS


Média – Banda 1




Desvio-padrão – Banda 1




Razão – Banda 1




Média – Banda 2




Desvio-padrão – Banda 2




Razão – Banda 2




Média – Banda 3




Desvio-padrão – Banda 3




Razão – Banda 3





Média – Banda 4











Desvio-padrão – Banda 4




Razão – Banda 4




ATRIBUTOS ESPACIAIS (GEOMETRIA)






Densidade


ATRIBUTOS ESPACIAIS (TEXTURA)




Homogeneidade GLCM




Contraste GLCM




Dissimilaridade GLCM




Entropia GLCM




Média GLCM



Desvio-padrão GLCM



Correlação GLCM



Entropia GLDV

**DEDUÇÃO ANALÍTICA DA
INFLUÊNCIA DA
NORMALIZAÇÃO DOS DADOS
NA CLASSIFICAÇÃO POR MVG**

Considerando o vetor de variáveis originais:

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_p \end{bmatrix}$$

E o vetor das variáveis transformadas dado da forma:

$$Z = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_p \end{bmatrix} = \begin{bmatrix} k_1 \cdot x_1 \\ k_2 \cdot x_2 \\ \vdots \\ k_p \cdot x_p \end{bmatrix}$$

ou

$$Z = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_p \end{bmatrix} = \begin{bmatrix} k_1 & 0 & \cdots & 0 \\ 0 & k_2 & & 0 \\ \vdots & & \ddots & \vdots \\ 0 & 0 & \cdots & k_p \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_p \end{bmatrix}$$

ou ainda, na forma matricial:

$${}_p Z_1 = {}_p K_p \cdot {}_p X_1$$

A relação entre as matrizes de covariância das variáveis originais e transformadas pode ser dada por:

$$\Sigma_x = \frac{1}{(n-1)} \sum_{i=1}^n (X_i - M_x)(X_i - M_x)^T \quad (1)$$

$$\Sigma_z = \frac{1}{(n-1)} \sum_{i=1}^n (Z_i - M_z)(Z_i - M_z)^T \quad (2)$$

Note que:

$$M_z = K \cdot M_x \quad (3)$$

Então, de (1), (2) e (3)

$$\Sigma_z = \frac{1}{(n-1)} \sum_{i=1}^n K \cdot (X_i - M_z)(K \cdot (X_i - M_z))^T \quad (4)$$

$$\Sigma_z = \frac{1}{(n-1)} \sum_{i=1}^n K \cdot (X_i - M_z)(X_i - M_z) \cdot K^T \quad (5)$$

Observe que K é uma matriz diagonal, isto é, $K^T = K$, então:

$$\Sigma_z = \frac{1}{(n-1)} K \left[\sum_{i=1}^n (X_i - M_z)(X_i - M_z)^T \right] K \quad (6)$$

$$\Sigma_z = K \cdot \Sigma_x \cdot K \quad (7)$$

Considerando a função decisão MVG para uma classe qualquer:

$$G_x(X) = -\ln|\Sigma_x| - (X - \Sigma_x)^T \Sigma_x^{-1} (X - \Sigma_x) \quad (8)$$

$$G_z(Z) = -\ln|\Sigma_z| - (Z - \Sigma_z)^T \Sigma_z^{-1} (Z - \Sigma_z) \quad (9)$$

$$G_z(Z) = -\ln|K \cdot \Sigma_x \cdot K| - \left(K \cdot (X - \Sigma_x)^T \right) \left(K \cdot \Sigma_x \cdot K \right)^{-1} \left(K \cdot (X - \Sigma_x) \right) \quad (10)$$

Lembrando que:

$$\det(A \cdot B) = \det(A) \cdot \det(B) \quad (11)$$

$$(A \cdot B)^{-1} = B^{-1} \cdot A^{-1} \quad (12)$$

De (7) e (11) o primeiro termo de (10) fica,

$$\ln|K \cdot \Sigma_x \cdot K| = \ln|K| + \ln|\Sigma_x| + \ln|K| \quad (13)$$

$$\ln|K \cdot \Sigma_x \cdot K| = 2 \cdot \ln|K| + \ln|\Sigma_x| \quad (14)$$

O segundo termo de (10) fica,

$$= (X - \Sigma_x)^T \cdot K^T \cdot K^{-1} \cdot \Sigma_x^{-1} \cdot K^{-1} \cdot K \cdot (X - \Sigma_x) \quad (15)$$

sendo $K^T = K$

$$= (X - \Sigma_x)^T \Sigma_x^{-1} (X - \Sigma_x) \quad (16)$$

Então de (14) e (16) a função decisão de uma classe qualquer para as variáveis transformadas, fica:

$$G_z(Z) = -\ln|\Sigma_x| - (X - \Sigma_x)^T \Sigma_x^{-1} (X - \Sigma_x) - 2\ln|K| \quad (17)$$

$$G_z(Z) = G_x(X) - 2\ln|K| \quad (18)$$

Conclusão:

Uma transformação com diferentes fatores de escala em cada uma das p variáveis na função decisão final MVG, implica na adição ou subtração do termo $2\ln|K|$, que é independente da classe. Esse termo, que aparece idêntico nas funções decisão MVG de todas as classes não vai afetar o resultado da classificação.

ANEXO

7

ALGORITMOS EM *MATLAB*

```

% -----
% Histogramas das Classes
%
%
%
%
%
%
%
%
% -----
% ARQ=INPUT (' NOME DO ARQUIVO: ', 's');
% LOAD (ARQ);

CLEAR
CLC

% MENU PARA ESCOLHA DA CLASSES PARA GERAÇÃO DO HISTOGRAMA
CLAS=0;
WHILE (CLAS~=1 & CLAS~=2 & CLAS~=3 & CLAS~=4 & CLAS~=5 & CLAS~=6 & CLAS~=7 & CLAS~=8)
    CLAS = MENU ('ESCOLHA A CLASSE PARA VISUALIZAR O HISTOGRAMA: ', 'TELHADO CLARO', 'TELHADO ESCURO',
        'TELHADO CERÂMICA', 'VEGETAÇÃO ARBÓREA', 'VEGETAÇÃO RASTEIRA', 'SOLO EXPOSTO', 'VIAS',
        'HIDROGRAFIA' );
END;

% MENU PARA ESCOLHA DOS ATRIBUTOS
AE = MENU (' ATRIBUTOS ESPECTRAIS', 'SIM', 'NÃO');
AG = MENU (' ATRIBUTOS ESPACIAIS (GEOMETRIA)', 'SIM', 'NÃO');
AT = MENU (' ATRIBUTOS ESPACIAIS (TEXTURA)', 'SIM', 'NÃO');

% COR DAS BARRAS DO HISTOGRAMA
COLOR = 'B';
% Y - YELLOW
% M - MAGENTA
% C - CYAN
% R - RED
% G - GREEN
% B - BLUE
% W - WHITE
% K - BLACK

% LEITURA DO ARQUIVO DE ATRIBUTOS NO FORMATO ORIGINAL
ATRIB_ORIGINAL = XLSREAD('OBJ_AMOSTRAS.XLS');

% MENU PARA LEITURA DO ARQUIVO DE ATRIBUTOS NO FORMATO NORMALIZADO OU ORIGINAL
NORM = MENU ('ESCOLHA A FORMA DO HISTOGRAMA', 'ATRIBUTOS NORMALIZADOS', 'ATRIBUTOS ORIGINAIS');

IF NORM == 1
    LOAD ATRIBUTOS_NORMALIZADOS;
    ATRIB_NORMAL=ATRIB_NORMAL_ARRED;
ELSE
    ATRIB_NORMAL = ATRIB_ORIGINAL;
END

% CRIAÇÃO DE MATRIZES DE AMOSTRAS POR CLASSE
% MONTAGEM DOS VETORES DE CLASSES

J=1;
FOR I = 1: SIZE(ATRIB_ORIGINAL,1)
    IF ATRIB_ORIGINAL(I,39) == CLAS
        CLASSE(J,:) = ATRIB_NORMAL(I,:);
        J = J+1;
    END
END
END

```



```

% RÓTULOS DE CLASSES PARA OS RODAPÉS DOS HISTOGRAMAS
IF CLAS==1
    RODAPE = SPRINTF('CLASSE= %3s ', 'TELHADO CLARO ');
END
IF CLAS==2
    RODAPE = SPRINTF('CLASSE= %3s ', 'TELHADO ESCURO ');
END
IF CLAS==3
    RODAPE = SPRINTF('CLASSE= %3s ', 'TELHADO CERÂMICA ');
END
IF CLAS==4
    RODAPE = SPRINTF('CLASSE= %3s ', 'VEGETAÇÃO ARBÓREA ');
END
IF CLAS==5
    RODAPE = SPRINTF('CLASSE= %3s ', 'VEGETAÇÃO RASTEIRA ');
END
IF CLAS==6
    RODAPE = SPRINTF('CLASSE= %3s ', 'SOLO EXPOSTO ');
END
IF CLAS==7
    RODAPE = SPRINTF('CLASSE= %3s ', 'VIAS ');
END
IF CLAS==8
    RODAPE = SPRINTF('CLASSE= %3s ', 'HIDROGRAFIA ');
END

```

```

% RÓTULOS DE ATRIBUTOS PARA OS RODAPÉS DOS HISTOGRAMAS
[ATRIBUTO] = [
    SPRINTF(' ATRIBUTO= %3s ', 'MEAN - BANDA 1 ');
    SPRINTF(' ATRIBUTO= %3s ', 'STDDEV - BANDA 1 ');
    SPRINTF(' ATRIBUTO= %3s ', 'RATIO - BANDA 1 ');
    SPRINTF(' ATRIBUTO= %3s ', 'MEAN - BANDA 2 ');
    SPRINTF(' ATRIBUTO= %3s ', 'STDDEV - BANDA 2 ');
    SPRINTF(' ATRIBUTO= %3s ', 'RATIO - BANDA 2 ');
    SPRINTF(' ATRIBUTO= %3s ', 'MEAN - BANDA 3 ');
    SPRINTF(' ATRIBUTO= %3s ', 'STDDEV - BANDA 3 ');
    SPRINTF(' ATRIBUTO= %3s ', 'RATIO - BANDA 3 ');
    SPRINTF(' ATRIBUTO= %3s ', 'MEAN - BANDA 4 ');
    SPRINTF(' ATRIBUTO= %3s ', 'STDDEV - BANDA 4 ');
    SPRINTF(' ATRIBUTO= %3s ', 'RATIO - BANDA 4 ');
    SPRINTF(' ATRIBUTO= %3s ', 'BRIGHTNESS ');
    SPRINTF(' ATRIBUTO= %3s ', 'MAX.DIFF. ');
    SPRINTF(' ATRIBUTO= %3s ', 'AREA ');
    SPRINTF(' ATRIBUTO= %3s ', 'LENGTH ');
    SPRINTF(' ATRIBUTO= %3s ', 'WIDTH ');
    SPRINTF(' ATRIBUTO= %3s ', 'LENGTH/WIDTH ');
    SPRINTF(' ATRIBUTO= %3s ', 'COMPACTNESS ');
    SPRINTF(' ATRIBUTO= %3s ', 'ELLIPTIC FIT ');
    SPRINTF(' ATRIBUTO= %3s ', 'RECTANGULAR FIT ');
    SPRINTF(' ATRIBUTO= %3s ', 'BORDER LENGTH ');
    SPRINTF(' ATRIBUTO= %3s ', 'SHAPE INDEX ');
    SPRINTF(' ATRIBUTO= %3s ', 'DENSITY ');
    SPRINTF(' ATRIBUTO= %3s ', 'MAIN DIRECTION ');
    SPRINTF(' ATRIBUTO= %3s ', 'ASYMMETRY ');
    SPRINTF(' ATRIBUTO= %3s ', 'GLCM HOMOGENEITY ');
    SPRINTF(' ATRIBUTO= %3s ', 'GLCM CONTRAST ');
    SPRINTF(' ATRIBUTO= %3s ', 'GLCM DISSIMILARITY ');
    SPRINTF(' ATRIBUTO= %3s ', 'GLCM ENTROPY ');
    SPRINTF(' ATRIBUTO= %3s ', 'GLCM ANG. 2ND MOMENT ');
    SPRINTF(' ATRIBUTO= %3s ', 'GLCM MEAN ');
    SPRINTF(' ATRIBUTO= %3s ', 'GLCM STDDEV ');
    SPRINTF(' ATRIBUTO= %3s ', 'GLCM CORRELATION ');
    SPRINTF(' ATRIBUTO= %3s ', 'GLDV ANG. 2ND MOMENT ');
    SPRINTF(' ATRIBUTO= %3s ', 'GLDV ENTROPY ');
    SPRINTF(' ATRIBUTO= %3s ', 'GLDV MEAN ');
    SPRINTF(' ATRIBUTO= %3s ', 'GLDV CONTRAST ')]];

```

```

% RESOLUCAO DO HISTOGRAMA
REL = 100;

% GERACAO DOS HISTOGRAMAS

IF AE==1 & AG==1 & AT==1 %TODOS ATRIBUTOS
FOR I=1:38
    HIST(CLASSE(:,I),REL);
    C = FINDOBJ(GCA,'TYPE','PATCH');
    SET(C,'FACECOLOR',COLOR,'EDGECOLOR','w')
    TITLE ('HISTOGRAMAS DAS AMOSTRAS DE CLASSES')
    X = GET(GCA,'TITLE');
    SET(X,'FONTSIZE',15);
    XLABEL ([RODAPE, ATRIBUTO(I,:)]);
    H = GET(GCA,'XLABEL');
    SET(H,'FONTSIZE',12);
    FIGURE
END
END

IF AE==1 & AG==2 & AT==2 %SOMENTE ESPECTRAL
FOR I=1:14
    HIST(CLASSE(:,I),REL);
    C = FINDOBJ(GCA,'TYPE','PATCH');
    SET(C,'FACECOLOR',COLOR,'EDGECOLOR','w')
    TITLE ('HISTOGRAMAS DAS AMOSTRAS DE CLASSES')
    X = GET(GCA,'TITLE');
    SET(X,'FONTSIZE',15);
    XLABEL ([RODAPE, ATRIBUTO(I,:)]);
    H = GET(GCA,'XLABEL');
    SET(H,'FONTSIZE',12);
    FIGURE
END
END

IF AE==1 & AG==1 & AT==2 %ESPECTRAL+GEOMETRIA
FOR I=1:26
    HIST(CLASSE(:,I),REL);
    C = FINDOBJ(GCA,'TYPE','PATCH');
    SET(C,'FACECOLOR',COLOR,'EDGECOLOR','w')
    TITLE ('HISTOGRAMAS DAS AMOSTRAS DE CLASSES')
    X = GET(GCA,'TITLE');
    SET(X,'FONTSIZE',15);
    XLABEL ([RODAPE, ATRIBUTO(I,:)]);
    H = GET(GCA,'XLABEL');
    SET(H,'FONTSIZE',12);
    FIGURE
END
END

IF AE==1 & AG==2 & AT==1 %ESPECTRAL+TEXTURA
FOR I=1:14 & 27:38
    HIST(CLASSE(:,I),REL);
    C = FINDOBJ(GCA,'TYPE','PATCH');
    SET(C,'FACECOLOR',COLOR,'EDGECOLOR','w')
    TITLE ('HISTOGRAMAS DAS AMOSTRAS DE CLASSES')
    X = GET(GCA,'TITLE');
    SET(X,'FONTSIZE',15);
    XLABEL ([RODAPE, ATRIBUTO(I,:)]);
    H = GET(GCA,'XLABEL');
    SET(H,'FONTSIZE',12);
    FIGURE
END
END

```

```
IF AE==2 & AG==1 & AT==1 %GEOMETRIA+TEXTURA
  FOR I=15:38
    HIST(CLASSE(:,I),REL);
    C = FINDOBJ(GCA,'TYPE','PATCH');
    SET(C,'FACECOLOR',COLOR,'EDGECOLOR','w')
    TITLE ('HISTOGRAMAS DAS AMOSTRAS DE CLASSES')
    X = GET(GCA,'TITLE');
    SET(X,'FONTSIZE',15);
    XLABEL ([RODAPE, ATRIBUTO(I,:)]);
    H = GET(GCA,'XLABEL');
    SET(H,'FONTSIZE',12);
    FIGURE
  END
END

IF AE==2 & AG==2 & AT==1 %SOMENTE TEXTURA
  FOR I=27:38
    HIST(CLASSE(:,I),REL);
    C = FINDOBJ(GCA,'TYPE','PATCH');
    SET(C,'FACECOLOR',COLOR,'EDGECOLOR','w')
    TITLE ('HISTOGRAMAS DAS AMOSTRAS DE CLASSES')
    X = GET(GCA,'TITLE');
    SET(X,'FONTSIZE',15);
    XLABEL ([RODAPE, ATRIBUTO(I,:)]);
    H = GET(GCA,'XLABEL');
    SET(H,'FONTSIZE',12);
    FIGURE
  END
END

IF AE==2 & AG==1 & AT==2 %SOMENTE GEOMETRIA
  FOR I=15:26
    HIST(CLASSE(:,I),REL);
    C = FINDOBJ(GCA,'TYPE','PATCH');
    SET(C,'FACECOLOR',COLOR,'EDGECOLOR','w')
    TITLE ('HISTOGRAMAS DAS AMOSTRAS DE CLASSES')
    X = GET(GCA,'TITLE');
    SET(X,'FONTSIZE',15);
    XLABEL ([RODAPE, ATRIBUTO(I,:)]);
    H = GET(GCA,'XLABEL');
    SET(H,'FONTSIZE',12);
    FIGURE
  END
END
```



```
-----  
% Calculo das Estatísticas das Classes das Amostras de Teste  
%  
%  
%  
%  
%  
%  
%  
%  
%  
%  
%  
%-----  
  
% Leitura das amostras das classes  
load amostras  
  
for i = 1: size(amostras,2)  
    amostras(i).meantest = mean(amostras(i).test);  
    amostras(i).meantrain = mean(amostras(i).train);  
    amostras(i).covtest = cov(amostras(i).test);  
    amostras(i).covtrain = cov(amostras(i).train);  
end  
  
% Salvamento da variavel de amostras  
save amostras amostras
```

```

function buildCDA (nat, trshd)
% -----
% Função Geral: Algoritmo de Decisão em Árvore
% Aplicação do algoritmo do CDA para criação da árvore de decisão binária
% para classificação de imagens de alta resolução espacial a partir de
% objetos gerados pelo processo de segmentação
%
% Função: buildCDA (nat, trshd)
%       nat: numero de atributos que melhor representam o par de
%           classes selecionados pela Distância de Bhattacharyya
%       trshd: Limiar em escala percentual (0 a 100) para
%             atribuição de classes nos nós da árvore no
%             processo de classificação
%
% * exemplo de sintaxe da função:
% * buildCDA(10,90)
%
%                               Marlos Henrique Batista
%                               nov/2005
% -----

% Leitura das Amostras
load amostras

% Aplicação do algoritmo do CDA para criação da árvore de decisão binária
% para classificação de imagens
for nos = 1:(2^(size(amostras,2))-1) % O número de nós é igual a ( 2^nº de
classes) - 1

% Atribuição das classes no nó inicial da árvore
if nos == 1
    arvore(1).no = [];
    for i = 1:size(amostras,2)
        arvore(1).no = [arvore(1).no,i];
    end
end

if size(arvore(nos).no,2) >= 3

    % Chamada da função que calcula da distância de Bhattacharyya
    bhatta (arvore(nos).no)
    % Salvamento das classes mais separáveis, determinada pela
    % distância de Bhattacharyya
    load root
    vartree(nos).root=root;
    % Salvamento das classes de cada nó
    vartree(nos).classe=arvore(nos).no;

    % Chamada da função para o calculo do SFS
    sfs (root(1),root(2),nat)
    % Salvamento dos atributos selecionados pelos SFS em cada nó
    load a
    vartree(nos).atributos=a;

    % Chamada da função que calcula da máxima verossimilhança
    maxver (root(1),root(2),nat)
    % Salvamento das estatísticas das classes em cada nó
    load g
    load treen
    vartree(nos).stats = treen;
    vartree(nos).maxver = g;

    % Chamada da função que monta o CDA
    cda(root(1),root(2),nat,trshd,nos)

    % Atribuição das classes nos nós filhos, definidos pelo CDA

```

```

        load treeb
        arvore(nos*2).no = treeb(1).no;
        arvore(nos*2+1).no = treeb(2).no;

    elseif size(arvore(nos).no,2) == 2    % Quando o nó tem duas classes

        % Salvamento das classes de cada nó
        vartree(nos).classe=arvore(nos).no;

        % Chamada da função para o calculo do SFS
        sfs (arvore(nos).no(1),arvore(nos).no(2),nat)
        % Salvamento dos atributos selecionados pelos SFS em cada nó
        load a
        vartree(nos).atributos=a;

        % Chamada da função que calcula da máxima verossimilhança
        maxver (arvore(nos).no(1),arvore(nos).no(2),nat)
        % Salvamento das estatísticas das classes em cada nó
        load g
        load treen
        vartree(nos).stats = treen;
        vartree(nos).maxver = g;

        % Atribuição das classes nos nós filhos
        arvore(nos*2).no = arvore(nos).no(1);
        arvore(nos*2+1).no = arvore(nos).no(2);

    elseif size(arvore(nos).no,2) == 2    % Quando o nó tem uma classes

        % Salvamento das classes de cada nó
        vartree(nos).classe=arvore(nos).no;

        % Atribuição das classes nos nós filhos
        arvore(nos*2).no = arvore(nos).no(1);
        arvore(nos*2+1).no = arvore(nos).no(2);

    else % Quando o nó é nulo

        % Salvamento das classes de cada nó
        vartree(nos).classe=arvore(nos).no;

        % Atribuição das classes nos nós filhos
        arvore(nos*2).no = [];
        arvore(nos*2+1).no = [];

    end

    % Display de percentual processado
    total=((2^(size(amostras,2)))-1);
    perct=(nos/total)*100;
    sprintf('Processing: %0.2g',perct)

end

% Organização das classes mais distantes e dos nós terminais na propriedade
% (classdist) da variável vartres
for i = 1:size(vartree,2)
    if size(vartree(i).classe,2) >= 3
        vartree(i).classdist = vartree(i).root;
    elseif size(vartree(i).classe,2) <= 2
        vartree(i).classdist = vartree(i).classe;
    end
end

save arvore arvore
save vartree vartree

```

```

function bhatta (selclass)
% -----
% Primeira parte: calculo da distância de Bhattacharyya para determinação
% das duas classes mais separáveis
%
% Função: bhatt (selclass)
%           selclass: classes que deseja-se calcular a separabilidade
%                   via distância de Bhattacharyya
%
% * exemplo de sintaxe da função:
% * bhatta ([1,3,6,7])
%
% Marlos Henrique Batista
% ago/2005
% -----
% Leitura das amostras das classes
load amostras

% Seleção das classes que serão calculadas na distância de Bhattacharyya
class = [];
for i = 1:size(amostras,2)
    class(i).all = 1;
    class(i).sel = 0;
    for j = 1:size(selclass,2)
        if selclass(j) == i
            class(i).sel = 100;
        end
    end
end

% Cálculo da distância de Bhattacharyya
% b será uma matriz quadrada, de dimensão igual ao numero de classes
% exemplo de chamada de média por variáveis estruturadas:
% amostras(classsel).meantrain(atributo1) - media da classe 1 no atributo 1
i = 1;
b.distall = [];
for wi = 1: size(amostras,2)
    for wj = 1:size(amostras,2)
        if class(i).sel == 100
            b.distall(i,j) = 1/8 * (amostras(wi).meantrain-amostras(wj).meantrain) *
            inv((amostras(wi).covtrain+amostras(wj).covtrain)/2) * (amostras(wi).meantrain-
            amostras(wj).meantrain)' + 0.5 * (
            logdet(0.5*(amostras(wi).covtrain+amostras(wj).covtrain)) - (
            (logdet(amostras(wi).covtrain))*0.5 + (logdet(amostras(wj).covtrain))*0.5 ) );
            j = j+1;
        end
    end
end

% Atribuição de distâncias nulas para as classes não definidas como
% variáveis de entrada na função
for i = 1:size(amostras,2)
    if class(i).sel ~= 100
        b.distall(:,i) = 0;
    end
end

% Determinação do par de classes com maior separabilidade
[dbhatt,pos_classe] = max (b.distall);
maxdist = max (dbhatt);
root = [];
for l = 1:size(amostras,2)
    for c = 1:size(amostras,2)
        if b.distall(l,c) == maxdist
            root = [l,c];
        end
    end
end
save root root
save selclass selclass

```

```

for i = 1:size(selclass,2)

    if selclass(i)==wi
        treeb(1).no(k) = wi;
        k = k+1;

    elseif selclass(i)==wj
        treeb(2).no(m) = wj;
        m = m+1;

    else
        % Calculo do percentual de classificação em cada nó (esquerda e
        % direita)
        neperc(i) = ( (size(treen(selclass(i))).ne,1)/size(treen(selclass(i))).sel,1)
)*100 ); %classificação no nó da esquerda
        ndperc(i) = ( (size(treen(selclass(i))).nd,1)/size(treen(selclass(i))).sel,1)
)*100 ); %classificação no nó da direita

        if neperc(i)<=trshd & ndperc(i)<=trshd % & (selclass(i)~=wi |
selclass(i)~=wi) % classificação no nó da esquerda e da direita
            treeb(1).no(k) = selclass(i);
            treeb(2).no(m) = selclass(i);
            k = k+1;
            m = m+1;
        end

        if neperc(i)>=trshd & ndperc(i)<=trshd % & (selclass(i)~=wi |
selclass(i)~=wi) % classificação no nó da esquerda
            treeb(1).no(k) = selclass(i);
            k = k+1;
        end

        if neperc(i)<=trshd & ndperc(i)>=trshd % & (selclass(i)~=wi |
selclass(i)~=wi) % classificação no nó da direita
            treeb(2).no(m) = selclass(i);
            m = m+1;
        end

    end

end

end

%         sprintf('nó esquerdo contem as classes: %d \n',treeb(1).no)
%         sprintf('nó direito contem as classes: %d \n',treeb(2).no)

save treeb treeb
save treen treen

```



```

if no2lwjt == 0
    no2lwj = 0;
end

% Teste para verificar a classe vencedora
if maxv(wi) > maxv(wj) % wi vence
    if no2wi > no2lwi % verifica se a classe vencedora esta no (no*2)
        if size(vartree(no*2).classdist,2) == 2 % verifica se é um nó
valido
            wi = vartree(no*2).classdist(1);
            wj = vartree(no*2).classdist(2);
            no = no*2;
        elseif size(vartree(no*2).classdist,2) == 1 % verifica se é nó
terminal
            nt = vartree(no*2).classdist(1);
            no = 1000;
        end
    else % indica que a classe vencedora esta no (no*2+1)
        if size(vartree(no*2+1).classdist,2) == 2 % verifica se é um nó
valido
            wi = vartree(no*2+1).classdist(1);
            wj = vartree(no*2+1).classdist(2);
            no = no*2+1;
        elseif size(vartree(no*2+1).classdist,2) == 1 % verifica se é nó
terminal
            nt = vartree(no*2+1).classdist(1);
            no = 1000;
        end
    end
end

elseif maxv(wi) < maxv(wj) % wj vence
    if no2wj > no2lwj % verifica se a classe vencedora esta no (no*2)
        if size(vartree(no*2).classdist,2) == 2 % verifica se é um nó
valido
            wi = vartree(no*2).classdist(1);
            wj = vartree(no*2).classdist(2);
            no = no*2;
        elseif size(vartree(no*2).classdist,2) == 1 % verifica se é nó
terminal
            nt = vartree(no*2).classdist(1);
            no = 1000;
        end
    else % indica que a classe vencedora esta no (no*2+1)
        if size(vartree(no*2+1).classdist,2) == 2 % verifica se é um nó
valido
            wi = vartree(no*2+1).classdist(1);
            wj = vartree(no*2+1).classdist(2);
            no = no*2+1;
        elseif size(vartree(no*2+1).classdist,2) == 1 % verifica se é nó
terminal
            nt = vartree(no*2+1).classdist(1);
            no = 1000;
        end
    end
end
end

% sprintf('classe terminal: %d \n',nt)

save nt nt
save vartree vartree

```

