

**HIDEO ARAKI**

**FUSÃO DE INFORMAÇÕES ESPECTRAIS, ALTIMÉTRICAS E DE  
DADOS AUXILIARES NA CLASSIFICAÇÃO DE IMAGENS DE ALTA  
RESOLUÇÃO ESPACIAL**

**Tese apresentada ao Curso de Pós-  
Graduação em Ciências Geodésicas,  
Setor de Ciências da Terra,  
Universidade Federal do Paraná, como  
requisito parcial à obtenção do título de  
Doutor em Ciências Geodésicas.**

**Orientador: Prof. Dr. Jorge Antonio  
Silva Centeno**

**CURITIBA**

**2005**

# **Livros Grátis**

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

**“FUSÃO DE INFORMAÇÕES ESPECTRAIS, ALTIMÉTRICA E  
DE DADOS AUXILIARES NA CLASSIFICAÇÃO DE IMAGENS  
DE ALTA RESOLUÇÃO ESPACIAL”**

**POR**

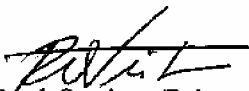
**HIDEO ARAKI**

Tese nº 042 aprovada como requisito parcial do grau de Doutor no  
Curso de Pós-Graduação em Ciências Geodésicas da Universidade  
Federal do Paraná, pela Comissão formada pelos professores:


Curitiba, 31 de outubro de 2005.



Prof. Dr. Jorge Antonio Silva Centeno - Orientador e Presidente (UFPR)



Prof. Dr. Raul Queiroz Feitosa - Membro (PUC-RJ)



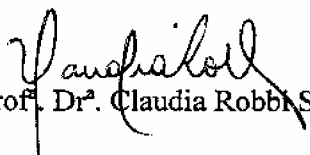
Prof. Dr. Luiz Felipe Guanaes Rego - Membro (PUC-RJ)



Prof. Dr. Quintino Dalmolin - Membro (UFPR)



Prof. Dr. Alzir Felipe Buffara Antunes - Membro (UFPR)



Prof. Dr.ª Claudia Robbi Sluter - Membro (UFPR)

## **AGRADECIMENTOS**

Agradeço a todos que direta ou indiretamente ajudaram na realização deste trabalho, em especial:

- Ao meu orientador, Prof. Dr. Jorge Antonio Silva Centeno, pelo incentivo na realização deste trabalho;
- Ao Curso de Pós-Graduação em Ciências Geodésicas;
- Ao Departamento de Geomática da UFPR;
- Aos colegas da Pós-Graduação em Ciências Geodésicas e do Departamento de Geomática.

## SUMÁRIO

<b>LISTA DE QUADROS E TABELAS</b> .....	vi
<b>LISTA DE FIGURAS</b> .....	vii
<b>RESUMO</b> .....	ix
<b>ABSTRACT</b> .....	x
<b>1 CONSIDERAÇÕES INICIAIS E OBJETIVOS</b> .....	1
1.1 CONSIDERAÇÕES INICIAIS.....	1
1.2 OBJETIVOS.....	10
1.3 JUSTIFICATIVA.....	10
1.4. ESTRUTURA DA TESE.....	12
<b>2 CLASSIFICAÇÃO, APRENDIZADO INDUTIVO E SISTEMA COM BASE EM REGRAS</b> .....	13
2.1 ALTA RESOLUÇÃO ESPACIAL.....	13
2.2 CARACTERÍSTICA DOS DADOS DO SISTEMA LASER SCANNER.....	16
2.3 ANÁLISE DIGITAL DE IMAGENS DE SENSORES REMOTOS.....	18
2.4 CLASSIFICAÇÃO.....	19
2.4.1 Classificação com base no pixel.....	25
2.4.2 Classificação com base em regiões.....	29
2.4.3 Comparação entre as abordagens com base no pixel e com base em regiões.....	31
2.5 FUSÃO DE DADOS.....	35
2.6 REPRESENTAÇÃO DO CONHECIMENTO.....	36
2.7 APRENDIZADO.....	38
2.8 ÁRVORE DE DECISÃO.....	39
2.8.1 Algoritmo ID3.....	42
2.8.2 Algoritmo C4.5 / C5.....	43
2.9 SISTEMAS ESPECIALISTAS.....	44
2.10 SISTEMAS COM BASE EM REGRAS.....	48
2.10.1 Representação da incerteza.....	48
2.11 SISTEMAS ESPECIALISTAS EM SENSORIAMENTO REMOTO.....	49
<b>3 ÁREA DE ESTUDO E INFRA-ESTRUTURA</b> .....	56
3.1 ÁREA DE ESTUDO.....	56
3.2 DESCRIÇÃO DOS DADOS.....	57
3.2.1 Dados laser scanner.....	57
3.2.2 Imagem Quickbird.....	58
3.2.2.1 Fusão das bandas multispectais e pancromática.....	58
3.2.3 Carta topográfica do centro politécnico.....	60
3.3 RECURSOS DE HARDWARE E SOFTWARE UTILIZADOS NA PESQUISA.....	61
3.3.1 Software Multispec.....	61
3.3.2 Software Matlab.....	62
3.3.3 Ambiente Java.....	63
3.3.4 Weka.....	64
3.3.5. Arcabouço de sistema especialista Jess.....	64
<b>4 METODOLOGIA</b> .....	72
4.1 PRÉ-PROCESSAMENTO DOS DADOS.....	72
4.1.1 Geração do MDS e da imagem intensidade.....	72
4.1.1.1 Metodologia proposta para a geração do MDS.....	73
4.1.1.2 Metodologia proposta para a geração da imagem intensidade.....	75
4.1.2 Pré-processamento da imagem Quickbird.....	75
4.1.2.1 Modelos geométricos para a geração da ortoimagem.....	76
4.1.2.2 Determinação dos parâmetros e geração da ortoimagem.....	79
4.2 CÁLCULO DA DECLIVIDADE E DA NORMAL A PARTIR DO MDSN.....	80
4.3 CORREÇÃO DO EFEITO RESIDUAL (ÁREAS DE OCLUSÃO).....	81
4.4 CONSTRUÇÃO DA BASE DE REGRAS PARA A CLASSIFICAÇÃO.....	84
4.5 CONSTRUÇÃO DA BASE DE CONHECIMENTO.....	88
4.6 CONSTRUÇÃO DO SISTEMA COM BASE EM REGRAS.....	89

<b>5 EXPERIMENTOS</b> .....	90
5.1 GERAÇÃO DO MODELO DIGITAL DE SUPERFÍCIE .....	90
5.2 GERAÇÃO DA IMAGEM INTENSIDADE .....	94
5.3 ORTORRETIFICAÇÃO DA IMAGEM QUICKBIRD.....	95
5.3.1 Modelagem geométrica .....	95
5.3.2 Geração da imagem ortorretificada .....	97
5.3.3 Correção do efeito da visada inclinada.....	99
5.4 CONSTRUÇÃO DA BASE DE REGRAS .....	102
5.5 CLASSIFICAÇÃO COM O SISTEMA COM BASE EM REGRAS.....	108
5.6 INTERPRETAÇÃO VISUAL DA IMAGEM QUICKBIRD .....	109
5.7 ANÁLISE DO RESULTADO DA CLASSIFICAÇÃO.....	109
<b>6 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES</b> .....	117
6.1 CONSIDERAÇÕES FINAIS .....	117
6.2 RECOMENDAÇÕES .....	120
<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	122

## LISTA DE QUADROS E TABELAS

QUADRO 1.1 - COMPARATIVO ENTRE LANDSAT 7, SPOT 5, IKONOS, QUICKBIRD E ORBVIEW. ....	2
TABELA 2.1 - EXATIDÃO DA CLASSIFICAÇÃO PARA DIFERENTES RESOLUÇÕES ESPACIAIS .....	15
TABELA 2.2 - EXATIDÃO DA CLASSIFICAÇÃO DA IMAGEM IKONOS COM O MÉTODO DA MÁXIMA VEROSSIMILHANÇA (SHACKELFORD & DAVIS, 2002) .....	26
TABELA 2.3 - MATRIZ DE ERROS PARA A IMAGEM COLUMBIA CLASSIFICADA COM O MÉTODO DA MÁXIMA VEROSSIMILHANÇA (SHACKELFORD & DAVIS, 2002) .....	27
QUADRO 2.1 - CARACTERÍSTICAS DE ALGUNS OBJETOS URBANOS .....	27
TABELA 2.4 - COMPARATIVO ENTRE AS CLASSIFICAÇÕES COM BASE NO PIXEL E COM BASE EM REGIÕES (VAN DE VOORDE ET AL, 2004) .....	33
TABELA 5.1 - DIFERENÇAS ENTRE COORDENADAS MEDIDAS NA CARTA TOPOGRÁFICA E NO MODELO DIGITAL DE SUPERFÍCIE .....	93
TABELA 5.2 - RESÍDUOS PARA OS PONTOS DE CONTROLE E DE VERIFICAÇÃO .....	96
TABELA 5.3 - DIFERENÇAS ENTRE COORDENADAS MEDIDAS NA CARTA TOPOGRÁFICA E NA ORTOIMAGEM QUICKBIRD .....	101
QUADRO 5.1 - NÍVEIS DE CLASSIFICAÇÃO .....	103
TABELA 5.4 - ERROS PARA AS CLASSES “ASFALTO” E “CONCRETO” .....	105
TABELA 5.5 - MATRIZ DE ERROS REFERENTE À COMPARAÇÃO ENTRE A INTERPRETAÇÃO VISUAL E A IMAGEM CLASSIFICADA COM O SISTEMA COM BASE EM REGRAS .....	114

## LISTA DE FIGURAS

FIGURA 1.1 - ÂNGULO RELATIVO ENTRE A CÂMARA, O ALVO E O SOL (CATS) .....	3
FIGURA 1.2 - A) MODELO DIGITAL DE ELEVAÇÃO, B) MODELO DIGITAL DE SUPERFÍCIE, E C) MODELO DIGITAL DE SUPERFÍCIE NORMALIZADO .....	5
FIGURA 1.3 - RECORTE DAS IMAGENS QUICKBIRD (À ESQUERDA) E HIPSOMÉTRICA (À DIREITA) .....	7
FIGURA 1.4 - MODELO DIGITAL DE SUPERFÍCIE GERADO COM O SOFTWARE ENVI .....	7
FIGURA 2.1 - CURVA DE REFLECTÂNCIA ESPECTRAL DE MATERIAIS PRESENTES EM ÁREAS URBANAS.....	15
FIGURA 2.2 - O FEIXE LASER E AS DIFERENTES REFLEXÕES.....	16
FIGURA 2.3 - MÉTODOS DE AGRUPAMENTO .....	20
FIGURA 2.4 - COMPONENTES DE UM PROCESSO DE CLASSIFICAÇÃO ESTATÍSTICA.....	21
FIGURA 2.5 - ESTRUTURA DAS REDES NEURAIS .....	22
FIGURA 2.6 - REDE SEMÂNTICA PARA AS CLASSES DEFINIDAS POR DUTTA E SERKER (2004).....	31
FIGURA 2.7 - ESPAÇO DE PADRÕES COM DUAS VARIÁVEIS (X1 E X2) E DOIS VALORES (1 E 2).....	39
FIGURA 2.8 - ÁRVORE DE DECISÃO CORRESPONDENTE AO ESPAÇO DE CARACTERÍSTICAS DA FIGURA 2.7.....	39
FIGURA 2.9 - MÓDULOS DE UM SISTEMA ESPECIALISTA .....	46
FIGURA 3.1 - COMPOSIÇÃO COLORIDAS DAS BANDAS 3, 2 E 1 ANTES E APÓS A FUSÃO.....	60
FIGURA 3.2 - COMPONENTES DE UM SISTEMA ESPECIALISTA COM BASE EM REGRAS .....	69
FIGURA 4.1 - ORTORRETIFICAÇÃO COM O MAPEAMENTO INVERSO.....	80
FIGURA 4.2 - MÁSCARA UTILIZADA PARA O CÁLCULO DO GRADIENTE E DA NORMAL.....	80
FIGURA 4.3 - GEOMETRIA DE IMAGEAMENTO.....	82
FIGURA 4.4 - ELEMENTOS PARA O CÁLCULO DAS ÁREAS DE OCLUSÃO .....	83
FIGURA 4.5 - REPRESENTAÇÃO DO ESQUEMA PARA A CONSTRUÇÃO DA BASE DE CONHECIMENTO.....	85
FIGURA 4.6 - ESQUEMA DA CLASSIFICAÇÃO .....	86
FIGURA 4.7 - FLUXO DE DADOS NO SISTEMA COM BASE EM REGRAS .....	89
FIGURA 5.1 - ETAPAS DA CONSTRUÇÃO DO MDS: A) PROJEÇÃO DOS PONTOS (N,E,H); B) PREENCHIMENTO CONSIDERANDO UM CRITÉRIO DE HOMOGENEIDADE; C) APLICAÇÃO DO OPERADOR MORFOLÓGICO FECHAMENTO; D) PREENCHIMENTO DAS ÁREAS DE OCLUSÃO.....	91
FIGURA 5.2 - SUPERPOSIÇÃO DO ARQUIVO VETORIAL DA CARTA DO CENTRO POLITÉCNICO SOBRE O MDS .....	92
FIGURA 5.3 - DIFERENÇA ENTRE A UTILIZAÇÃO DOS MAIORES VALORES E MENORES VALORES DE ALTITUDE PARA A GERAÇÃO DO MDS.....	93
FIGURA 5.4 - RESULTADOS GERADOS NOS PASSOS INICIAL E FINAL DA CONSTRUÇÃO DA IMAGEM INTENSIDADE .....	94
FIGURA 5.5 - DISTRIBUIÇÃO DOS PONTOS DE CONTROLE E DE VERIFICAÇÃO .....	96
FIGURA 5.6 - RESÍDUOS PARA OS PONTOS DE VERIFICAÇÃO, OBTIDOS COM O POLINÔMIO RACIONAL DE GRAU 1.....	97
FIGURA 5.7 - RECORTE DA BANDA PANCROMÁTICA DA IMAGEM QUICKBIRD.....	98



FIGURA 5.8 - RECORTE DA IMAGEM PANCROMÁTICA APÓS A APLICAÇÃO DA CORREÇÃO GEOMÉTRICA.....	98
FIGURA 5.9 - ÁREAS DE OCLUSÃO NA IMAGEM QUICKBIRD.....	99
FIGURA 5.10 - APLICAÇÃO DA MÁSCARA COM AS REGIÕES DE OCLUSÃO SOBRE A IMAGEM ORTORRETIFICADA .....	100
FIGURA 5.11 - APLICAÇÃO DA MÁSCARA COM AS ÁREAS DE OCLUSÃO PARA A REGIÃO DE EDIFICAÇÕES MAIS ALTAS.....	100
FIGURA 5.12 - SUPERPOSIÇÃO DO ARQUIVO VETORIAL SOBRE A IMAGEM ORTORRETIFICADA .....	101
FIGURA 5.13 - RECORTE DA IMAGEM QUICKBIRD (BANDAS 3,2,1) E DA IMAGEM INTENSIDADE.....	102
FIGURA 5.14 - PARTE DA ÁRVORE DE DECISÃO GERADA PELO ALGORITMO J4.8.....	107
FIGURA 5.15 - ESQUEMA DO SISTEMA COM BASE EM REGRAS.....	108
FIGURA 5.16 - COMPOSIÇÃO RGB DAS BANDAS 4,3,2 (ESQUERDA) E A CORRESPONDENTE ANÁLISE VISUAL (DIREITA).....	110
FIGURA 5.17 - CLASSIFICAÇÃO COM 12 ATRIBUTOS (ESQUERDA) E 13 ATRIBUTOS (DIREITA).....	111
FIGURA 5.18 - CLASSIFICAÇÃO EFETUADA COM 13 ATRIBUTOS, E POSTERIOR JUNÇÃO DAS CLASSES COM OCLUSÃO .....	112
FIGURA 5.19 - SUPERPOSIÇÃO DO ARQUIVO VETORIAL DA CARTA DO CENTRO POLITÉCNICO SOBRE A IMAGEM CLASSIFICADA .....	113
FIGURA 5.20 - COMPARAÇÃO ENTRE A CARTA DO CENTRO POLITÉCNICO E A IMAGEM CLASSIFICADA.....	113
FIGURA 5.21 - COMPARAÇÃO ENTRE A INTERPRETAÇÃO VISUAL (ESQUERDA) E A IMAGEM CLASSIFICADA COM O SISTEMA COM BASE EM REGRAS (DIREITA).....	114
FIGURA 5.22 - RESULTADO DA CLASSIFICAÇÃO PARA EDIFICAÇÕES ISOLADAS E PRÓXIMAS ENTRE SI .....	116

## RESUMO

As imagens de alta resolução proporcionam informação espacial detalhada da superfície terrestre, fazendo com que feições urbanas, como edificações, sejam representadas por vários pixels. Porém, a informação espectral presente nestas imagens é insuficiente para a classificação da cobertura do solo urbano. Em áreas urbanas existe oclusão, causando perda de informação espectral em algumas regiões da imagem. Este problema pode ser contornado com a disponibilidade de dados altimétricos adquiridos pelos sistemas laser scanner aerotransportados, melhorando a discriminação entre os tipos de cobertura. Outra possibilidade é a utilização de informações auxiliares existentes em bases cartográficas para auxiliar a discriminação entre as classes. Para que a fusão de dados destas diferentes fontes seja possível, a referência espacial deve ser comum. O método para a classificação deve lidar com dados correspondentes a escalas de medidas numéricas e nominais, e não depender da atribuição de uma determinada distribuição estatística para as classes. As árvores de decisão constituem uma alternativa para a classificação supervisionada, sendo que também possibilitam a explicitação do conhecimento. Por sua vez, o conhecimento explicitado por algoritmos de indução de árvores de decisão pode ser representado na forma de regras que formam a base de regras de um sistema com base em regras. Sistemas com base em regras podem ser construídos a partir de arcabouços como o Jess (*Java Expert System Shell*) que fornecem a funcionalidade, bastando construir a base de regras e fornecer os fatos (os pixels) a serem analisados. Neste contexto, pode-se efetuar a classificação de imagens de alta resolução espacial com base no pixel, combinando as informações espectrais, altimétrica e de dados auxiliares.

## **ABSTRACT**

High resolution images provides fine spatial information about the surface, and urban features such as buildings are represented by many pixels. But spectral information, derived from images, is not sufficient for urban land cover classification. In urban areas, occlusion effects are produced by tall buildings and in these areas the land cover information can be lost. It is possible to achieve better land cover type discrimination by using altimetric information provided by airborne laser scanners. Another possibility is to use ancillary information provided by cartographic databases. The data source must be arranged to a common spatial reference when drawing inferences from several available sources in data fusion, and available data are not always numeric, they can be nominal too. Multistage classification technique provided by decision trees is a valid alternative in supervised classification. Using decision trees, knowledge can be represented and used in a knowledge-based analysis system. Expert system shell such as Jess (Java Expert System Shell) can be used in a rule-based expert system. In this context, a pixel based classification of high resolution images, by combining spectral information, elevation and ancillary data can be performed.

## 1. CONSIDERAÇÕES INICIAIS E OBJETIVOS

### 1.1 CONSIDERAÇÕES INICIAIS

Recentemente, o sensoriamento remoto passou a ser considerado como uma alternativa para o mapeamento de áreas urbanas, com a utilização de imagens de satélite de alta resolução espacial e de dados adquiridos pelos sensores *lidar* (*light detection and ranging*) aerotransportados, também conhecidos como *laser scanners*. As imagens de sensores de alta resolução espacial proporcionam informações mais detalhadas da cobertura da superfície da Terra do que as imagens anteriormente disponíveis. Dentre as possíveis novas aplicações para áreas urbanas, podem ser citadas: inventário de parcelas construídas, mapeamento de superfícies impermeáveis, mapeamento e avaliação de áreas verdes intra-urbanas, identificação de complexos morfológicos urbanos, determinação da densidade de edificações e a identificação e quantificação de espaços vazios.

Em contraste com as imagens anteriormente disponíveis, como as obtidas pelos sensores a bordo dos satélites Landsat e Spot 4, tornou-se possível o imageamento com resoluções espacial, radiométrica e temporal melhoradas. Entretanto as técnicas largamente utilizadas para a análise de imagens de satélite foram desenvolvidas para as imagens com média resolução espacial (20 m a 100 m).

Os elementos presentes em cada cena, tanto em áreas de agricultura, em áreas naturais ou em áreas urbanas, apresentam problemas que são únicos para a análise de imagens. Por exemplo, a aparência de objetos naturais pode variar grandemente devido à localização geográfica, à estação, às condições climáticas atuais e passadas. Já as áreas urbanas apresentam combinações de feições artificiais e naturais, fazendo com que a análise de imagens seja uma tarefa ainda mais difícil. Existe grande variedade de representações pictóricas de objetos com o mesmo significado semântico e extensa quantidade de detalhes, como ruas, casas, edifícios ou

diferentes tipos de vegetação. Embora entidades presentes em áreas urbanas possuam em geral contornos bem definidos, as estruturas podem estar parcialmente ocultas conforme o ângulo de visão e sombras de estruturas podem obscurecer parcelas do terreno. As áreas construídas colocam vários desafios para o processamento de imagens, como a necessidade de lidar com a existência de sombras e de oclusões devido a estruturas verticais. O uso de imagens de sensores multiespectrais atuais para o mapeamento de ambientes urbanos tem limitações, considerando a semelhança espectral de diferentes materiais como telhas, superfícies de ruas, solo exposto e entre diferentes tipos de vegetação urbana (HEROLD et al, 2004).

O quadro 1.1 apresenta uma comparação dos sensores de alta resolução (Ikonos, Quickbird e Orbview 3) com os sensores ETM do Landsat 7 e do SPOT 5.

QUADRO 1.1 - COMPARATIVO ENTRE LANDSAT 7, SPOT 5, IKONOS, QUICKBIRD E ORBVIEW.

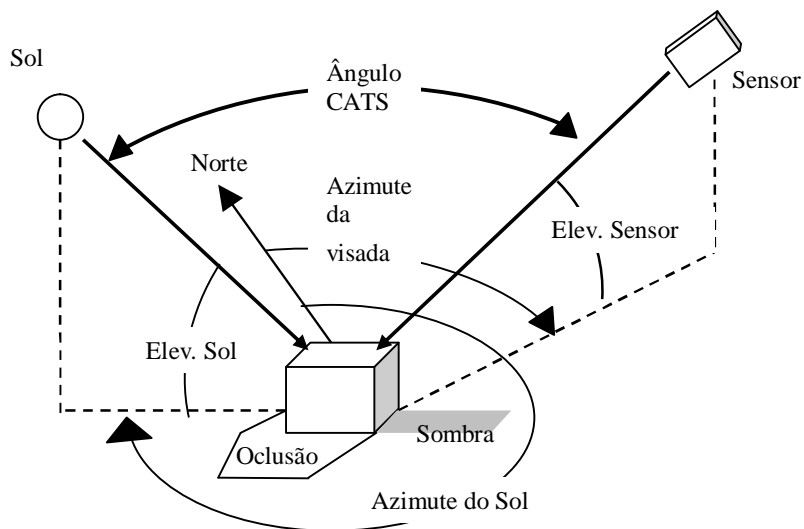
LANDSAT 7	SPOT 5	IKONOS	QUICKBIRD	ORBVIEW
Pancromático (15 m) 0.52 a 0.90 $\mu\text{m}$	Pancromático (2,5 e 5m) 0.48 - 0.71 $\mu\text{m}$	Pancromático (1m) 0.45 - 0.90 $\mu\text{m}$	Pancromático (0,7 m) 0.45 - 0.90 $\mu\text{m}$	Pancromático (1m) 0.45 - 0.90 $\mu\text{m}$
Multiespectral (30m) B1 0.45 a 0.52 $\mu\text{m}$ B2 0.52 a 0.60 $\mu\text{m}$ B3 0.63 a 0.69 $\mu\text{m}$ B4 0.75 a 0.90 $\mu\text{m}$ B5 1.55 a 1.75 $\mu\text{m}$ B6 10.4 a 12.5 $\mu\text{m}$ B7 2.09 a 2.35 $\mu\text{m}$	Multiespectral (10m) B1 0.50 a 0,59 $\mu\text{m}$ B2 0.61 a 0.68 $\mu\text{m}$ B3 0.78 - 0.89 $\mu\text{m}$ B4 1.58 a 1.75 $\mu\text{m}$	Multiespectral (4m) B1 0.45 a 0.52 $\mu\text{m}$ B2 0.52 a 0.60 $\mu\text{m}$ B3 0.63 a 0.69 $\mu\text{m}$ B4 0.76 a 0.90 $\mu\text{m}$	Multiespectral (2,5m) B1 0.45 a 0.52 $\mu\text{m}$ B2 0.52 a 0.60 $\mu\text{m}$ B3 0.63 a 0.69 $\mu\text{m}$ B4 0.76 a 0.90 $\mu\text{m}$	Multiespectral (4m) B1 0.45 a 0.52 $\mu\text{m}$ B2 0.52 a 0.60 $\mu\text{m}$ B3 0.63 a 0.69 $\mu\text{m}$ B4 0.76 a 0.90 $\mu\text{m}$
Resolução radiométrica: 8 bits	Resolução radiométrica: 8 bits	Resolução radiométrica: 11 bits	Resolução radiométrica: 11 bits	Resolução radiométrica: 11 bits

Os sensores de alta resolução espacial adquirem atualmente imagens com menos bandas espectrais do que o Landsat TM, mais especificamente nas regiões visível e infra-vermelho do espectro eletromagnético. Com a possibilidade de direcionamento do sensor para a aquisição de imagens, tem-se a redução do tempo de revisita (resolução temporal) para a aquisição de imagens de um mesmo local. A aquisição de imagens de um mesmo local da superfície pode ser efetuada com um intervalo de 1,5 a 3 dias pelo Ikonos, e com cerca de 1 a 3 dias pelo QuickBird, mas as

imagens apresentam um efeito de perspectiva devido à tomada inclinada.

Para um sensor radiometricamente estável, é esperado que as imagens coletadas da mesma região em diferentes datas exibam características tonais semelhantes. Na realidade, diversos fatores externos afetam as medidas efetuadas pelos sensores (GERLACH, 2001). Entre estes fatores estão: a elevação solar, a geometria de coleta, as variações de inclinação superficial com relação ao Sol e a visada do satélite, além dos efeitos da atmosfera. O ângulo de elevação solar pode afetar o contraste aparente de um objeto; este efeito pode dificultar a geração de mosaicos a partir de várias imagens adquiridas pelo mesmo sensor. A geometria de coleta está relacionada à elevação do satélite e ao azimute relativo entre o sensor e o Sol (Figura 1.1). O ângulo entre os dois vetores, o primeiro, que liga o sensor à cena e, o segundo, que liga o Sol à cena, é denominado CATS (*câmera-target-sun*).

FIGURA 1.1- ÂNGULO RELATIVO ENTRE A CÂMARA, O ALVO E O SOL (CATS)  
(ADAPTADO DE GERLACH, 2001).



Para pequenos ângulos CAT, as sombras estarão atrás dos objetos, dificultando a identificação visual de objetos, e o efeito do espalhamento recebido pelo telescópio do sensor também pode diminuir o contraste da imagem. A inclinação superficial, a posição relativa do Sol e a visada do sensor podem fazer com que a

reflexão seja parcialmente ou totalmente especular dependendo do material superficial. Assim, duas edificações cobertas com o mesmo material, mas com diferentes inclinações, poderão ter valores de pixel bem diferentes na imagem. Na imagem coletada pelo sensor, as áreas atrás dos objetos imageados, isto é, áreas que não são visíveis para o sensor, são chamadas de áreas de oclusão.


A tecnologia *laser scanner* foi desenvolvida acompanhando a melhoria da qualidade do posicionamento GPS e a melhoria da capacidade de medida de atitude com unidades de medida inercial. São três as componentes envolvidas: o laser, o INS e o GPS diferencial. O GPS é utilizado para obter as coordenadas da posição do imageador, e o Sistema de Navegação Inercial (Inertial Navigation System, INS) determina a atitude da aeronave com elevada exatidão para pequenos períodos de tempo. A idéia básica é calcular as coordenadas polares para os pontos que causam a reflexão do sinal laser. O sistema de varredura laser possibilita a determinação da distância entre a plataforma e o ponto; a direção do feixe é calculada combinando o ângulo do sistema de varredura com o ângulo da aeronave, proporcionado pelo INS. A posição da aeronave e, portanto, a origem do feixe laser é conhecida usando GPS diferencial, e finalmente, as coordenadas de pontos da superfície terrestre podem ser calculadas em um sistema de referência.

A maioria dos sistemas *laser scanner* usa um pulso laser. Neste sistema a distância é determinada pela medida do tempo que a emissão laser, modulada por um pulso distinto de alguns nanosegundos, necessita para percorrer duas vezes a distância da aeronave à superfície. O feixe laser pode encontrar dois ou mais obstáculos; isto resulta em duas ou mais reflexões do feixe. A maioria dos sistemas é capaz de registrar todos os pulsos que retornam ao laser, ou pelo menos o primeiro e o último pulso. O resultado é um conjunto de coordenadas X, Y, Z, a partir das quais pode ser gerada uma grade regular por interpolação. Com base nestas medidas diferentes aplicações são possíveis, como a geração de modelos tridimensionais de áreas urbanas para aplicações em planejamento urbano ou realidade virtual.

Os dados registrados pelo laser scanner são usualmente utilizados na forma de

numa grade regular contendo valores interpolados a partir dos pontos medidos. A grade regular representando a superfície topográfica é denominada Modelo Digital de Elevação (MDE), o Modelo Digital de Terreno (DTM) incorpora a elevação de feições significativas que melhoram a caracterização da forma do terreno e o Modelo Digital de Superfície (MDS) representa copas de árvores e objetos feitos pelo homem, como as edificações. O Modelo Digital de Superfície normalizado (MDSn) corresponde à diferença entre o MDS e o MDE, sendo representadas as alturas das edificações e das árvores acima da superfície topográfica. A figura 1.2 ilustra a diferença entre o MDS, o MDE e o MDSn. Os dados medidos pelo laser scanner permitem a geração de MDS, e é necessário o processamento adicional para gerar o MDE ou o MDT. São amplamente utilizados softwares proprietários fornecidos pelo fabricante dos sistemas laser scanner para gerar os Modelos Digitais de Superfície (MDS).

FIGURA 1.2 - A) MODELO DIGITAL DE ELEVAÇÃO, B) MODELO DIGITAL DE SUPERFÍCIE, E C) MODELO DIGITAL DE SUPERFÍCIE NORMALIZADO.



Na literatura existe grande variedade de artigos tratando de aplicações de dados de laser scanner como, por exemplo, na reconstrução de edificações, seja a partir do MDS ou a partir de dados brutos, ou na filtragem para recuperação da forma da superfície do terreno (MDE). Poucos artigos tratam da questão da interpolação a partir de pontos medidos pelo sistema laser scanner; e quando são apresentadas




metodologias para a geração de modelos digitais, trata-se de modelos para finalidades específicas, como é o caso de RABEL et al (2002) que “retiram” a vegetação para obter o MDE.

O método utilizado para a geração do MDS afetará a exatidão da reconstrução de feições (edificações, árvores, ruas, etc) em aplicações como a geração de modelos 3D urbanos, e a possibilidade de recuperação de informações como a existência de linhas de transmissão de energia elétrica. Nestes casos, é recomendado que o espaçamento da grade seja similar à densidade dos pontos originais. Segundo AXELSSON (1999), os efeitos causados pela interpolação podem reduzir a quantidade de informação que pode ser extraída a partir do MDS. A figura 1.3 mostra um recorte da imagem Quickbird (à esquerda), e um recorte da imagem hipsométrica gerada com o software REALM (Optech) pelo LACTEC, combinando informação de elevação e intensidade (à direita); a cor vermelha corresponde às maiores elevações e o verde às menores elevações. Na imagem hipsométrica existem alguns problemas causados pela interpolação, como o surgimento de triângulos na superfície do lago, bem como a indefinição das bordas das edificações. Também pode ser verificado que ao lado das edificações existem regiões sem informação devido à oclusão (em preto).

SMITH et al (2003) realizaram testes para geração de grades com diferentes espaçamentos a partir de medidas do primeiro pulso, com os métodos de interpolação bilinear, bicúbico, vizinho mais próximo e splining biarmônico, e avaliaram erros decorrentes da interpolação. Eles verificaram que o método de interpolação utilizado para formar a grade regular a partir dos pontos medidos pode introduzir um grau de incerteza, e que este grau de incerteza varia de acordo com o método de interpolação. Dos métodos investigados, o algoritmo do vizinho mais próximo apresentou o maior erro, enquanto os dois métodos que apresentaram menor erro altimétrico, splining e bicúbico, suavizaram excessivamente as bordas de edificações. O erro foi considerado como sendo a diferença em elevação entre pontos medidos pelo laser e os correspondentes valores nas superfícies interpoladas.

FIGURA 1.3 - RECORTE DAS IMAGENS QUICKBIRD (À ESQUERDA) E HIPSOMÉTRICA (À DIREITA).



Outros experimentos foram realizados por ZINGER et al (2002), utilizando krigagem e interpolações linear e do vizinho mais próximo para a geração de grade regular a partir de superfícies dos triângulos resultantes da triangulação de Delaunay. São relatadas ocorrência de problemas: a) ao utilizar a interpolação linear, em bordas e na representação de fachadas de edificações (superfícies verticais); (b) ao utilizar o vizinho mais próximo, na representação de superfícies inclinadas como os telhados. Já ao utilizar a krigagem, alguns parâmetros podem ser modificados para expressar dependência espacial, mas foi verificado um efeito de suavização de bordas.

FIGURA 1.4 - MODELO DIGITAL DE SUPERFÍCIE GERADO COM O SOFTWARE ENVI.



A figura 1.4 mostra um recorte da grade gerada com o algoritmo disponível no ENVI a partir dos pontos correspondentes ao último pulso. Este algoritmo efetua a triangulação de Delaunay para então fazer a interpolação a partir das faces dos triângulos. As áreas de oclusão foram mascaradas pelos triângulos espúrios gerados, sendo que as áreas correspondentes ao telhado das edificações ficaram maiores do que na realidade. O algoritmo implementado no ENVI não conseguiu realizar a interpolação para a grade espaçada de 70cm, ocorrendo “vazios” (em preto) na grade gerada.

Pode-se concluir que não é recomendável utilizar a triangulação de Delaunay quando da geração da grade regular, pois um triângulo pode ter como vértice um ponto no topo de uma edificação e outro no solo, gerando triângulos espúrios a partir dos quais serão interpolados valores na grade regular. Lastimosamente, este tipo de algoritmos é muito comum em softwares de sensoriamento remoto (como, por exemplo, ENVI e ErMapper), pois suas funções eram concebidas para a interpolação de modelos digitais de elevação, assumindo a disponibilidade de dados esparsos e áreas de relevo suave.

O coeficiente de reflexão do material presente na cena determina a porção do sinal emitido que retornará ao laser. A maioria dos sistemas de varredura (*scanners*) de "segunda geração" oferece a possibilidade de registrar o valor de intensidade do sinal que retorna. Como a reflectância depende do material superficial, a diferenciação entre os tipos de material é possível; a vegetação possui valor de reflectância mais alto do que materiais artificiais como asfalto ou concreto.

A natureza dos dados captados usando este sistema é diferente dos métodos tradicionalmente utilizados em sensoriamento remoto e, por conseguinte, torna-se uma ferramenta complementar muito importante. A possibilidade de combinar dados de sistemas laser scanner com imagens de sensores de alta resolução ganha, neste contexto, grande importância e pode ser apontada como uma alternativa viável e promissora (CENTENO, 2001).

Conforme KIEMA e BÄHR (2000), o uso de dados altimétricos obtidos com ajuda de sistemas laser scanner isoladamente tem pouca aplicabilidade, especialmente quando se deseja segmentar e reconhecer objetos urbanos. Isto se deve essencialmente à restrição da geometria superficial que limita o número de objetos que podem ser discriminados no modelo digital de superfície gerado a partir dos pontos medidos. Para realçar sua utilidade e explorar todo o potencial, é frequentemente necessário integrar estes dados com outras fontes complementares como, por exemplo, dados multiespectrais. A informação geométrica contida nos dados altimétricos pode ser usada para auxiliar a segmentação de objetos que se projetam acima do terreno (como prédios e árvores) em relação a outros que estão no nível do terreno (como pavimentos, jardins e outros).

Associando os dados obtidos com um laser scanner com a informação disponível em imagens de sensores de alta resolução, é possível melhorar a análise de objetos que apresentam características espectrais semelhantes, mas que estão situados a diferentes elevações, como telhados e solo exposto, ou gramado e árvores. A integração de informações obtidas por diferentes sensores auxilia a análise de áreas urbanas, bem como a explicitação do conhecimento envolvido e de como o analista humano, partindo de imagens, descreve e representa objetos do mundo real.

A extração automatizada de informações demanda métodos que consigam reproduzir a capacidade humana de interpretar uma imagem. Neste contexto, ganha significado a integração de novos métodos de análise como, por exemplo, o uso de técnicas de inteligência artificial, para representar o conhecimento do analista humano em programas para efetuar a classificação de imagens. A emulação em computadores do método de interpretação aplicado pelo homem ainda está em estágio muito inicial, mas as técnicas de inteligência artificial têm dado um impulso para o avanço neste campo.

## 1.2 OBJETIVOS

A hipótese básica considerada neste trabalho é: “seria possível melhorar a classificação de imagens de alta resolução espacial em uma abordagem com base no pixel, incorporando dados auxiliares provenientes de levantamentos por laser scanner e mapas?”

O **objetivo geral** é: efetuar a fusão de informações espectrais, altimétricas e de dados auxiliares na classificação de imagens de alta resolução espacial.

Os **objetivos específicos** são:

- propor uma metodologia para a geração de Modelo Digital de Superfície a partir de coordenadas (E, N, h) de pontos medidos pelo laser scanner;
- propor uma metodologia para a correção geométrica de imagens de satélite de alta resolução espacial, visando a geração de ortoimagem;
- verificar se a imagem correspondente à intensidade do retorno laser pode suprir a falta de informações nas áreas de sombra e de oclusão na imagem Quickbird ortorretificada;
- propor uma metodologia para a aquisição do conhecimento a ser colocado numa base de conhecimento de um sistema com base em regras. Será construída a base de conhecimento, e realizada a classificação utilizando esta base de conhecimento.

## 1.3 JUSTIFICATIVA

As imagens de satélite de alta resolução permitem acompanhar as alterações em termos da cobertura do solo em áreas urbanas, podendo ser uma ferramenta importante para o planejamento urbano e para a verificação da atualidade do cadastro técnico. No entanto, as técnicas de análise de imagens atualmente disponíveis em programas comerciais ainda não estão plenamente adaptadas para possibilitarem a análise digital de imagens de alta resolução. A análise por um especialista humano proporciona uma riqueza de informações que ainda não é possível obter

computacionalmente.

Quanto à correção geométrica de imagens de alta resolução, alternativas como a ortorretificação de imagens Quickbird e Ikonos estão disponíveis em software comerciais, mas estão restritas à aplicação dos coeficientes polinomiais fornecidos pelas empresas proprietárias dos satélites, e não conseguem tratar os efeitos de perspectiva devido à visada inclinada e da oclusão.

A geração de produtos como Modelos Digitais de Superfície a partir de medidas efetuadas com laser scanner depende de software proprietário. Já os softwares de tratamento de imagens de sensores remotos não conseguem lidar adequadamente com o grande volume de dados tridimensionais gerados com sistemas laser scanner, além de não disporem de algoritmos adequados para a geração do Modelo Digital de Superfície. Assim, torna-se necessário desenvolver algoritmos para a geração do Modelo Digital de Superfície que minimizem os problemas decorrentes de interpolação durante a geração de grades regulares a partir de coordenadas tridimensionais de um conjunto de pontos.

Quanto à integração de dados de diferentes sensores, a possibilidade de utilização de árvores de decisão é uma alternativa existente em software comercial. A base de conhecimento deve ser criada pelo usuário na forma de regras. No entanto, ainda é um esforço inicial no sentido de aplicação de sistemas com base em regras, bastante desenvolvidas em outras áreas do conhecimento com as ferramentas da inteligência artificial.

Assim, busca-se com este trabalho tratar os aspectos referentes à ortorretificação de imagens de satélite de alta resolução, à geração de Modelo Digital de Superfície a partir de coordenadas de pontos medidos com sistemas de laser scanner aerotransportados, à geração da imagem com os dados de intensidade do retorno laser, e à integração destes dados com informação cartográfica num sistema com base em regras. Tal sistema com base em regras será construído no ambiente Java utilizando o arcabouço de sistema especialista Jess. A base de conhecimento será elaborada com o auxílio de ferramentas de aprendizado de máquina, na forma de uma árvore de

decisão, e poderá ser confrontada com o conhecimento de um especialista humano.

Com a integração das informações da imagem Quickbird, dos dados obtidos com laser scanner e da base cartográfica (ruas) pretende-se verificar a qualidade da classificação e a possibilidade de que informações faltantes numa das fontes, como as áreas de oclusão na imagem Quickbird, possam ser compensadas pelas outras fontes. Os resultados da classificação permitirão avaliar se o sistema com base em regras possibilita efetuar adequadamente a fusão de informações de diferentes fontes.

#### 1.4 ESTRUTURA DA TESE

Este texto está estruturado da seguinte forma: O capítulo 2 apresenta uma revisão de conceitos relativos ao sensoriamento remoto e ao campo da inteligência artificial, abordando os métodos de classificação com base no pixel e com base em regiões e apresentando uma revisão bibliográfica relativa à comparação entre os dois métodos; também são apresentados conceitos relativos ao aprendizado indutivo com árvores de decisão e elementos de um sistema com base em regras, seguido de uma revisão bibliográfica acerca da utilização de sistemas especialistas em sensoriamento remoto. No capítulo 3 é apresentada a área de estudo, e são descritos os dados e os recursos utilizados no desenvolvimento da pesquisa, incluindo o arcabouço de sistema especialista Jess. No capítulo 4 são apresentadas as metodologias propostas para a geração do Modelo Digital de Superfície e da imagem intensidade do retorno laser, para a ortorretificação da imagem Quickbird, e para a construção do sistema com base em regras. No capítulo 5 são apresentados os resultados dos experimentos relativos à geração do Modelo Digital de Superfície, à ortorretificação e à classificação com o sistema com base em regras. Finalmente, o capítulo 6 contém as considerações finais e as sugestões para trabalhos futuros.

## **2. CLASSIFICAÇÃO, APRENDIZADO INDUTIVO E SISTEMA COM BASE EM REGRAS**

Este capítulo tem o intuito de apresentar revisão de conceitos básicos relativos ao sensoriamento remoto e ao campo da inteligência artificial, e também a revisão bibliográfica relativa às aplicações de técnicas de inteligência artificial, mais especificamente de sistemas com base em regras, em sensoriamento remoto. Com relação ao sensoriamento remoto, são abordadas questões como alta resolução espacial, classificação e segmentação de imagens, abordagens com base no pixel e com base em regiões, e comparações entre estas duas abordagens para áreas urbanas. Também são apresentados conceitos relativos ao aprendizado indutivo com árvores de decisão, sendo que as árvores de decisão permitem gerar conhecimento simbólico que pode ser expresso na forma de regras. Por fim, são apresentados os elementos de um sistema com base em regras, e resultados de experimentos com a utilização de sistemas especialistas em sensoriamento remoto, na pós-classificação, na classificação integrando dados de imagens com dados de outras fontes, bem como na utilização de árvores de decisão para a construção da base de regras. Em cada experimento citado, procurou-se destacar também os fatores que influíram nos resultados relatados.

### **2.1 ALTA RESOLUÇÃO ESPACIAL**

A resolução espacial está associada à dimensão do elemento de imagem, o pixel, quando projetado no terreno. Resoluções espaciais mais altas correspondem a menores dimensões quando da projeção do pixel no terreno. A alta resolução espacial corresponde à situação em que um único objeto do mundo real é representado por muitos pixels, enquanto baixa resolução implica que um único pixel representa o sinal proveniente de muitos objetos do mundo real. Em sensoriamento remoto ocorrem simultaneamente as situações de alta e baixa resolução numa imagem. Por exemplo, em uma imagem de uma cobertura florestal, onde cada copa tem diâmetro de 10m, e



sendo de 1m a resolução espacial, cada objeto copa será representado por vários pixels. Nesta situação, cada pixel de 1m é parte de uma copa individual e, portanto, tem alta resolução em relação ao objeto copa. No entanto, cada pixel de 1m será também composto pela reflectância integrada de muitas folhas e galhos e, assim, terá baixa resolução em relação a estes componentes da copa. Como resultado, um objeto na imagem tende a ser composto de pixels espacialmente agrupados que exibem alta autocorrelação espacial porque são parte do mesmo objeto e, conseqüentemente, tem valores de pixel similares (HAY et al, 2003).

HUIPING et al (2003) relatam um experimento visando analisar o efeito da resolução espacial na classificação tradicional, para uma imagem obtida por um sensor não orbital. Uma imagem com três bandas na região visível (R, G e B) com resolução espacial de 10 cm foi reamostrada, gerando imagens com resolução espacial de 20cm, 50 cm e 1m. Foram definidas nove classes: ruas, caminhos, edificações grandes, edificações pequenas, árvore, arbusto, grama, água e sombra. O resultado da classificação foi comparado com a interpretação visual, dados de campo e outras fontes de informação. Cada classe apresentou variação na exatidão conforme a resolução espacial. A exatidão da classificação, para as diferentes resoluções está mostrada na tabela 2. Algumas classes melhoram a exatidão com o aumento da resolução, como é o caso de árvores pequenas e isoladas. Já a classe grama teve maior exatidão com a resolução de 1m.

Para as imagens de satélite de alta resolução, à medida que ocorre o aumento da resolução espacial, o desempenho da classificação é afetado por dois fatores: a) aumento da variabilidade intra-classe, e b) "efeito de borda". A variabilidade intra-classe pode ter origem, para um mesmo material superficial, nas condições de iluminação solar e sombra; materiais artificiais podem ter a mesma composição, mas a sua superfície pode ter cores diferentes. O efeito de borda está associado a "pixels mistura". Pixels puros são aqueles que contêm apenas uma classe de cobertura do solo, enquanto pixels mistura são aqueles que contêm duas ou mais classes. Os pixels mistura freqüentemente ocorrem nas bordas entre duas ou mais classes. Para feições


pequenas ou lineares, ocorre um menor erro de classificação com o aumento da resolução espacial, especialmente devido ao decréscimo da proporção de pixels mistura em relação ao total de pixels.

TABELA 2.1 - EXATIDÃO DA CLASSIFICAÇÃO PARA DIFERENTES RESOLUÇÕES ESPACIAIS (HUIPING ET AL, 2003)

Classes: 1-ruas; 2 - caminhos; 3 -edificações grandes; 4 - edificações pequenas; 5 - árvores; 6 - arbustos; 7 - grama; 8 - água; 9 - sombras	Resolução	Classes								
		1	2	3	4	5	6	7	8	9
	10cm	52%	42%	39%	57%	59%	57%	47%	51%	52%
	20cm	55%	50%	40%	59%	54%	43%	50%	60%	59%
	50cm	64%	25%	48%	67%	44%	43%	61%	68%	46%
	1m	60%	17%	54%	43%	33%	29%	70%	54%	37%

A figura 2.1 apresenta a reflectância de materiais típicos de áreas urbanas. A similaridade espectral entre tipos de telhados e ruas se deve à propriedade dos materiais usados e são responsáveis pela inexatidão na classificação de áreas urbanas. Os sensores de alta resolução espacial apresentam limitações no mapeamento detalhado de áreas urbanas devido à largura das bandas espectrais e ao fato de não adquirirem imagens no infravermelho médio, região onde se tem melhor separabilidade entre algumas das classes.

FIGURA 2.1 - CURVA DE REFLECTÂNCIA ESPECTRAL DE MATERIAIS PRESENTES EM ÁREAS URBANAS (HEROLD et al, 2004).



A diversidade de materiais artificiais e de estruturas tridimensionais em áreas


urbanas resulta em heterogeneidade espacial e espectral, fazendo com que a análise digital de imagens urbanas utilizando apenas as bandas multiespectrais dos satélites de alta resolução não seja adequada.

## 2.2 CARACTERÍSTICA DOS DADOS DO SISTEMA LASER SCANNER

A técnica de varredura a laser (laser scanning) é de crescente importância para a aquisição de imagens de objetos 3D, especialmente para o reconhecimento e reconstrução de edificações em áreas urbanas. Existem várias abordagens para a modelagem de edificações por meio de dados altimétricos obtidos por um laser scanner; algumas utilizam apenas dados medidos pelo sistema laser, enquanto outras utilizam fontes adicionais de informações, como mapas digitais, imagens espectrais ou outros dados disponíveis em sistemas de informações geográficas (SIG).

Os pulsos emitidos pelo laser possuem uma característica de divergência à medida que os mesmos se propagam no ar, formando o diâmetro do pulso. A área de cobertura de cada feixe emitido pelo laser scanner é variável de acordo com a altitude, é possível que uma porção do mesmo feixe laser encontre um ou mais objetos antes de atingir o solo, como mostrado na Figura 2.2.

FIGURA 2.2 - O FEIXE LASER E AS DIFERENTES REFLEXÕES.



No primeiro pulso, tem-se a reflexão no nível mais elevado, e no último

pulso (na mesma posição horizontal), tem-se a reflexão correspondente ao nível do solo. O sistema laser scanner armazena dados tanto do primeiro como também do último retorno. De posse desses dois tipos de informações, é possível obter diferentes modelos digitais, ou seja, Modelo Digital de Superfície (MDS) representando todas as feições existentes, ou só do último retorno e mediante a remoção das árvores e outras feições existentes acima da superfície topográfica, o Modelo Digital de Elevação (MDE). A diferença entre o Modelo Digital de Superfície (MDS) e o Modelo Digital de Terreno (MDE) é denominado Modelo Digital de Superfície Normalizado (MDSn).

Um efeito resultante dos modos de medida (primeiro pulso e último pulso) se manifesta nas discontinuidades de estruturas elevadas, como bordas de edificações. A mesma edificação pode ter dimensão maior ou menor, dependendo do sinal utilizado. STEINLE e VÖGTLE (2000) verificaram que os telhados reconstruídos com o primeiro pulso têm boa coincidência com as linhas de mapas cadastrais, mas muitos detalhes como antenas, chaminés, etc, podem perturbar a determinação de suas superfícies. No último pulso parte da vegetação é quase eliminada, o que pode ser vantajoso para o reconhecimento de edificações. A desvantagem da utilização do último pulso é que as edificações ficam menores, e ocorre perda de detalhes dos telhados. Também a orientação da edificação em relação à orientação do sistema de varredura é um dos fatores que contribuem para a diferença de dimensão entre o primeiro e o último pulso, sendo a diferença maior quando as bordas estão perpendiculares ou paralelas à orientação da varredura (SANTOS et al, 2003).

A intensidade é definida como a razão entre a luz refletida e a luz emitida, e é influenciada principalmente pela reflectância do objeto. A reflectância varia com as características do material e com o comprimento de onda utilizado, e cada material tem um comportamento característico em função de suas propriedades físicas e químicas. Conseqüentemente, a intensidade pode ser uma informação útil para a classificação da cobertura do solo. Entretanto, o sinal correspondente à intensidade do retorno contém muito ruído. O principal aspecto determinante do nível de ruído é o ângulo de reflexão, sendo que para alguns materiais a intensidade terá diferentes valores em função do

ângulo de reflexão (SONG et al, 2002).

### 2.3 ANÁLISE DIGITAL DE IMAGENS DE SENSORES REMOTOS

Uma das principais metas da análise de imagens por computador é a de dotar uma máquina da capacidade similar à que têm os seres humanos de descoberta, de identificação e de entendimento de padrões relevantes (GONZALEZ & WOODS, 2000). Esta é uma tarefa difícil, como salientado por SCHALKOFF (1989): "muito frequentemente uma tarefa de processamento de imagens é considerada trivial até se tentar codificar o algoritmo". O sistema computacional deve iniciar a análise partindo dos valores numéricos, os pixels da imagem. Entretanto, a informação semântica necessária para interpretar uma imagem não está representada em pixels isolados, mas em objetos significativos e em suas relações múltiplas. Por exemplo, o uso do solo urbano é um conceito abstrato que é definido em termos de função e não em termos de formas perceptíveis na imagem.

A classificação de imagens multiespectrais é um passo importante em sensoriamento remoto, análise de imagens e reconhecimento de padrões. A classificação é necessária para a extração de informação temática da cena. O objetivo geral da classificação da cobertura do solo é a identificação de elementos que exibem características homogêneas, e o agrupamento destes elementos, reduzindo neste processo a variabilidade de valores que estão numa escala numérica (níveis de cinza) para uma escala nominal (CHUVIECO, 1996).

Os novos sensores trazem novos problemas para a análise automática de imagens (SCHIEWE, 2002):

1. novas técnicas são necessárias para processamento e análise eficientes;
2. a disponibilidade de dados de múltiplos sensores e fontes cria a necessidade de fusão de dados, em particular ao nível de decisão. No entanto, as técnicas convencionais de classificação não são capazes de lidar com fontes de dados heterogêneos e com informação contextual.

## 2.4 CLASSIFICAÇÃO

Desde que as primeiras imagens multiespectrais se tornaram disponíveis a partir dos satélites civis de sensoriamento remoto, tem havido um esforço considerável na produção de mapas temáticos a partir de dados de sensores remotos. A classificação é o processo pelo qual a imagem de satélite é transformada num produto geográfico.

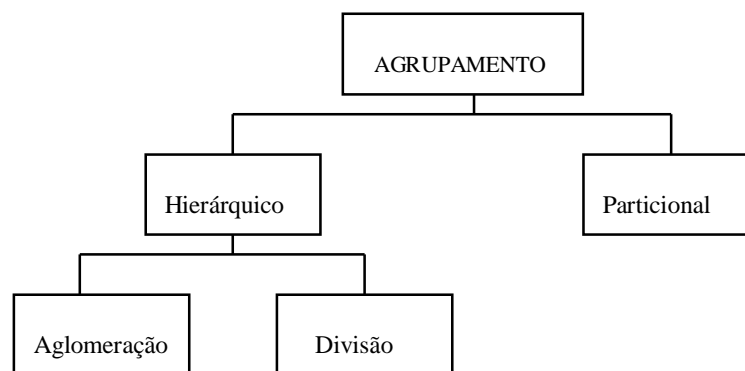
Conforme RICHARDS e JIA (1999), convém distinguir dois tipos de categorias que intervêm na classificação temática: classes de informação e classes espectrais. A classe de informação se refere às categorias de interesse identificadas na imagem, como as classes de ocupação do solo. A segunda se refere aos grupos de pixels uniformes (ou similares) com valores espectrais homólogos. As classes de informação são estabelecidas pelo usuário que, no procedimento de classificação, procura associá-las às classes espectrais, sendo que, na prática, pode não haver tal correspondência; uma classe de informação pode não corresponder a uma classe espectral, ou uma classe espectral pode estar associada a mais de uma classe de informação. Os métodos mais comuns de classificação podem ser agrupados em classificação supervisionada e classificação não supervisionada.

Na classificação não supervisionada, as classes resultam de um processo de agrupamento de pixels com propriedades espectrais semelhantes (classes espectrais), sem conhecimento anterior do nome destas classes. A classificação não supervisionada é realizada por métodos de *agrupamento (clustering)*, e pode ser utilizada para determinar a composição espectral da imagem. Diversos métodos de agrupamento têm sido desenvolvidos para diferentes propósitos, e a maioria dos algoritmos pode ser rotulada como sendo hierárquica ou particional (ver figura 2.3).

Métodos hierárquicos de agrupamento podem ser representados graficamente como um dendrograma. Um agrupamento hierárquico aglomerativo inicia com cada pixel representando um cluster, então funde clusters vizinhos que atenderem um critério de similaridade como o da menor distância espectral entre as médias. O dendrograma é um diagrama que mostra a similaridade entre os *clusters* que foram

agrupados. O processo de fusão dos clusters vizinhos é continuado até que todos os pixels estejam agrupados em um único cluster. O *clustering* hierárquico divisivo inicia com um único *cluster*, que é progressivamente subdividido. Os procedimentos de agrupamento hierárquico têm as vantagens de serem representações gráficas facilmente interpretadas e ignorarem a influência da inicialização e de mínimos locais. Entretanto, consideram apenas a vizinhança local quando fazem fusão/divisão de clusters e não podem incorporar conhecimento *a priori* sobre a forma ou tamanho global de clusters.

FIGURA 2.3 - MÉTODOS DE AGRUPAMENTO



Os procedimentos particionais de agrupamento incorporam conhecimento da característica local por meio de medidas apropriadas de distância. Do ponto de vista prático, os elementos são agrupados em volta de  $k$  sementes escolhidas de forma aleatória. As  $k$  classes criadas são representadas pelo centro de gravidade. Novas partições são realizadas agrupando os elementos a partir destes novos  $k$  núcleos que são os centros de gravidade do particionamento precedente. O processo é repetido até encontrar classes estáveis, ou seja, até que os centros de gravidade da iteração atual sejam iguais aos da iteração anterior. Os métodos de agrupamento mais aplicados a imagens de sensores remotos são particionais, como  $k$ -means e Isodata (SCHIEWE, 2002).

A classificação supervisionada é o procedimento mais utilizado na análise de dados em imagens de sensoriamento remoto, e usualmente é realizada com base numa

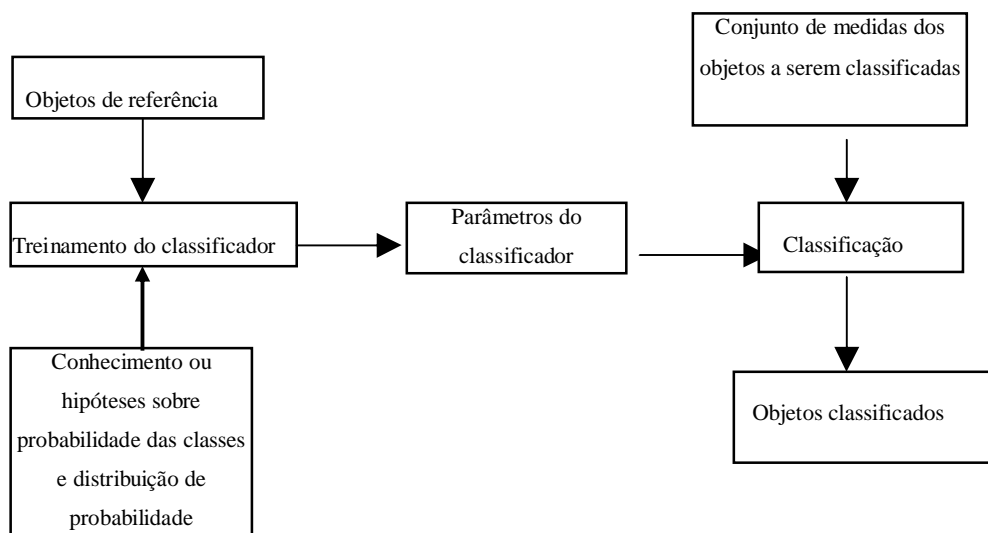
medida de semelhança, como a distância espectral, a função discriminante ou a função de verossimilhança. Existem vários métodos de classificação supervisionada, mas todos seguem os passos:

- Definir classes de informação como, por exemplo, água, regiões urbanas, etc.
- Escolher pixels representativos das classes (amostras), por meio de visitas ao local, mapas, fotografias aéreas ou até mesmo outra imagem interpretada.
- Usar as amostras para estimar os parâmetros a serem usados pelo classificador.
- Usar o classificador treinado para classificar cada pixel da imagem.

As classes de informação devem ser cuidadosamente selecionadas e definidas. As amostras podem ser definidas por meio de uma combinação de trabalho de campo, análise de fotografias aéreas e mapas, e experiência pessoal do analista. As amostras são utilizadas para a obtenção dos descritores numéricos de cada classe ou tipo de cobertura presente na cena.

Uma importante suposição na classificação estatística é a de que as classes espectrais podem ser descritas por uma distribuição de probabilidade no espaço multidimensional. A figura 2.4 mostra as componentes de um processo de classificação estatística.


FIGURA 2.4 – COMPONENTES DE UM PROCESSO DE CLASSIFICAÇÃO ESTATÍSTICA  
(Adaptado de FISCHLER e FIRSCHEIN, 1987)





Outra opção para a classificação é o uso de técnicas não paramétricas, como é o caso de redes neurais. Segundo PAOLA & SCHOWENGERDT (1997), as redes neurais são mais robustas do que os métodos estatísticos quando as classes apresentam distribuição não gaussiana. As redes neurais são usualmente organizadas em camadas compostas de unidades de processamento (os neurônios) conectados por canais de comunicação (as conexões) que fazem fluir dados numéricos. Um único neurônio tem capacidade limitada de processamento, mas vários neurônios podem ser combinados em uma camada ou em camadas múltiplas, ampliando a capacidade da rede. Os dados (padrões) são apresentados à rede por meio da camada de entrada, a qual se comunica a uma ou mais camadas ocultas onde ocorre o processamento por meio do sistema de conexões. A camada de saída apresenta o resultado do processamento. A figura 2.5 mostra uma rede neural consistindo de três camadas (de entrada, oculta e de saída), recebendo como entrada o valor de um pixel da imagem multiespectral com cinco bandas (X1, X2, X3, X4, X5) e gerando como saída a correspondente classe (C1 ou C2).

FIGURA 2.5 – ESTRUTURA DAS REDES NEURAI



A definição da arquitetura de uma rede neural consiste na especificação do número de camadas de neurônios, do número de neurônios em cada camada, da função de transferência de cada camada, e de como as camadas estão conectadas entre si. Uma vez definida a estrutura da rede, deve-se encontrar um conjunto adequado de pesos para as conexões. As redes neurais utilizadas para a classificação supervisionada são

treinadas até que o erro entre a saída desejada e a saída da rede para as amostras atinja um mínimo pré-estabelecido. Os pesos das conexões entre os neurônios são ajustados na etapa de treinamento e correspondem ao conhecimento adquirido pela rede neural. Na fase de classificação são apresentados os dados da imagem (pixels) e os pesos excitam ou inibem a ativação dos neurônios, gerando a classificação.

O exemplo mais conhecido de algoritmo para aprendizado supervisionado para redes de múltiplas camadas é algoritmo *backpropagation* ou retropropagação. HEPNER et al. (1990) verificaram que as redes neurais podem classificar imagens acuradamente com um conjunto de amostras para cada classe menor do que o necessário para a classificação estatística. Deve-se observar que diferentes algoritmos de classificação podem produzir resultados não idênticos, mesmo que sejam usadas as mesmas áreas de treinamento.

Conforme o elemento de imagem utilizado na classificação, os classificadores podem ser divididos em classificadores com base no pixel e classificadores por regiões. Os classificadores com base no pixel utilizam apenas a informação espectral, isoladamente, de cada pixel para encontrar regiões homogêneas.

Classificadores por regiões utilizam, além da informação espectral de cada pixel, a informação espacial que envolve a relação entre o pixel e seus vizinhos. Estes classificadores procuram simular o comportamento do foto-intérprete ao reconhecer áreas homogêneas na imagem, baseado nas propriedades espectrais e espaciais de imagens.

WILKINSON (2005) analisou artigos publicados na *Photogrammetric Engineering and Remote Sensing* num período de 15 anos, de janeiro de 1989 a dezembro de 2003, visando examinar o efeito dos desenvolvimentos nas técnicas de classificação de imagens. Neste período, aconteceram: 1) o desenvolvimento de componentes de algoritmos de classificação, incluindo estratégias de treinamento ou aprendizagem e abordagens para separação de classes com base em estimadores estatísticos e índices de separabilidade das classes; 2) o desenvolvimento de novas abordagens para a classificação, e 3) a exploração de múltiplos tipos de dados ou

informações auxiliares, numéricos ou não, no processo de classificação. Na primeira categoria podem ser incluídos desenvolvimentos do método da máxima verossimilhança, métodos de função de densidade de probabilidade n-dimensional, redes neurais artificiais, árvores de decisão, algoritmos genéticos, e análise da forma espectral. Na segunda categoria, podem ser incluídas abordagens como a lógica nebulosa, sistemas multiclassificadores que integram as saídas de diferentes algoritmos de classificação, e métodos de fusão de decisões. Na terceira categoria, podem ser incluídos o uso de medidas de textura extraídas da imagem, o uso de informação estrutural ou de contexto espacial, o uso de dados de diversas fontes, e o uso de conhecimento geográfico auxiliar integrado ao sistema de classificação, por exemplo, por meio de abordagens de sistema especialista.

O estudo realizado por WILKINSON (2005) revela que, como um todo, não houve uma melhoria nos resultados das classificações ao longo do tempo. Embora alguns experimentos individuais possam demonstrar a vantagem de uma técnica comparada a outras, não existe uma tendência nos resultados identificados. Algumas questões levantadas neste estudo são:

- As classes utilizadas para o mapeamento da cobertura do solo são conceitos humanos e não estão diretamente relacionados aos sinais físicos detectados e medidos pelos sensores. Tais conceitos são subjetivos, e as pessoas têm diferentes entendimentos. Isto implica que não existe uma única solução “correta” para a transformação de uma paisagem em um arranjo bidimensional de parcelas representando classes individuais. As definições de classes são vagas, e paisagens não apresentam contornos bem definidos para as parcelas. As tentativas de utilizar classificação *fuzzy* podem ajudar, mas mesmo ela não pode lidar com a variabilidade inerente ao mundo natural.

- Outro problema relacionado com a definição de classes é a estratégia de amostragem utilizada para definir as amostras de treinamento e teste. A amostragem não apropriada pode introduzir correlação espacial entre conjuntos de treinamento e teste, invalidando o processo de avaliação da exatidão.

- As classes de informação são definidas de acordo com determinadas escalas de mapas. Por outro lado, os algoritmos de classificação tendem a operar num determinado espaço de escala (relacionado ao tamanho do pixel), sendo que as classes escolhidas para o mapeamento temático podem não ter significado neste espaço de escala. Por exemplo, se um pixel com resolução de 1m x 1m contém uma árvore, isto não implica necessariamente que o pixel é parte de uma floresta. O conceito de floresta implica para a maioria das pessoas uma extensão espacial mínima.

- A exatidão da classificação mede quão bem a abordagem de classificação coloca amostras em classes “corretas” definidas pela verdade de terreno. Entretanto, como o mapeamento de paisagens é subjetivo, a exatidão é definida de maneira arbitrária. A utilidade de um produto da classificação, tal como um mapa temático, depende da paisagem ter sido dividida apropriadamente em regiões para a aplicação de interesse. A exatidão e a utilidade podem coincidir em significado, se os indivíduos que produzem a verdade de terreno forem também os usuários finais do produto e tem a mesma compreensão de como a verdade de terreno foi definida e de como áreas incertas da paisagem foram tratadas.

#### 2.4.1 Classificação com base no pixel

Cada pixel de uma imagem multiespectral pode ser representado por um vetor, onde cada elemento do vetor corresponde a uma banda espectral. Na maioria das técnicas de classificação, a discriminação entre as classes é feita com base nos valores presentes nestes vetores.

Áreas urbanas apresentam alta densidade de objetos (edificações, ruas, veículos e árvores) e alta proporção de áreas cobertas por sombras. Isto afeta o mapeamento detalhado de áreas urbanas usando imagens de satélite. Os métodos de classificação supervisionada, como o classificador da máxima verossimilhança, que consideram apenas a informação espectral, não são capazes de diferenciar as classes presentes em áreas urbanas com alto grau de exatidão.

SHACKELFORD & DAVIS (2002) realizaram a classificação da imagem multiespectral IKONOS com o método da máxima verossimilhança, para as bandas originais e também para as bandas híbridas (resultantes da fusão das bandas multiespectrais com a banda pancromática). As classes de informação utilizadas foram: “ruas”, “edificações”, “gramado”, “árvores”, “solo exposto”, “água” e “sombas”. A tabela 2.2 mostra a exatidão da classificação para as sete classes e para o agrupamento de ruas e edificações numa mesma classe (impermeável). Os principais erros de classificação ocorreram entre as classes “rua” e “edificações”, sendo que, da verdade de terreno, 26,3% de ruas foram classificadas como edificações, e 18% de edificações foram classificadas como ruas (ver tabela 2.3). Também ocorreram erros entre as classes “gramado” e “árvores” (16,6% de “gramado” classificados como “árvore”, e 10,9% de “árvore” classificados como “gramado”).

TABELA 2.2 - EXATIDÃO DA CLASSIFICAÇÃO DA IMAGEM IKONOS COM O MÉTODO DA MÁXIMA VEROSSIMILHANÇA (SHACKELFORD & DAVIS, 2002).

Tamanho do pixel	Imagem	Exatidão (6 classes)	Exatidão (7 classes)
4 m	Columbia	86,8 %	83,3 %
1 m	Columbia	87,9 %	80,9 %
4 m	Springfield	98,1 %	88,6 %
1 m	Springfield	98,4 %	90,8 %

Em áreas urbanas densas, uma possibilidade para melhorar a classificação é determinar as áreas de sombra e então aplicar uma correção a tais áreas. NAKAJIMA, TAO e YASSUOKA (2002) determinaram áreas de sombra mediante a utilização da informação de elevação a partir dos dados altimétricos obtidos com laser scanner e do azimute do Sol quando da aquisição da imagem.

Muitos objetos parecem muito similares nas imagens de alta resolução; por exemplo, telhados e ruas podem ser construídos com material similar, tendo, portanto, características semelhantes de reflectância. Na combinação de imagens com dados de altimétricos obtidos com laser scanner (TAO e YASUAOKA, 2002), tem-se a

possibilidade de separar as classes com base no índice de vegetação e na elevação, conforme o quadro 2.1.

TABELA 2.3 - MATRIZ DE ERROS PARA A IMAGEM COLUMBIA CLASSIFICADA COM O MÉTODO DA MÁXIMA VEROSSIMILHANÇA (SHACKELFORD & DAVIS, 2002)

Classificação	Verdade de Terreno					
	Ruas (%)	Edificações(%)	Água (%)	Solo exp. (%)	Gramado (%)	Árvore (%)
Sombras	0,1	4,8	26,3	0,0	0,0	0,0
Ruas	70,6	18,0	0,3	3,4	0,0	0,0
Edificações	26,3	72,8	4,2	0,6	0,2	0,0
Água	0,0	3,6	69,2	0,0	0,0	0,0
Solo exposto	1,5	0,3	0,0	96,0	0,0	0,0
Gramado	0,9	0,2	0,0	0,0	84,2	10,9
Árvore	0,5	0,4	0,0	0,0	16,6	89,1

QUADRO 2.1 - CARACTERÍSTICAS DE ALGUNS OBJETOS URBANOS.

Objeto	NDVI	MDSn
edificação	baixo	alto
ruas	baixo	baixo
Solo exposto	médio	baixo
Gramado	alto	baixo
Árvore	Muito alto	alto

YU et al (2002), utilizaram dados altimétricos do laser scanner para auxiliar a classificação da imagem multiespectral Ikonos. Os dados de elevação permitiram segmentar inicialmente a área urbana em três partes: acima do terreno, ao nível do terreno, e áreas de sombra. A seguir, o classificador da máxima verossimilhança foi utilizado para classificar separadamente cada uma das três partes, sendo as classes assim definidas: “edificações”, “ruas”, “solo exposto”, “árvores”, “áreas cobertas por grama” e “corpos d’água”.

Outra possibilidade é a utilização de métodos de análise de textura, sendo que, neste caso, as relações entre valores de cinza entre cada pixel e os pixels

próximos são calculados com base em uma determinada medida, como variância, contraste, correlação, entropia, energia (ZHANG, 2001). Na classificação de imagens de satélite, métodos de análise de textura são frequentemente usados para introduzir a informação espacial de diferentes classes de cobertura na classificação com base no píxel. Por exemplo, as classes “gramado” e “árvores” têm assinaturas espectrais semelhantes, mas as áreas cobertas com gramado são mais homogêneas do que as áreas cobertas por árvores. Normalmente, a imagem de saída gerada pela análise de textura é classificada diretamente, ou usada como uma banda adicional juntamente com as bandas multiespectrais.

SHACKELFORD & DAVIS (2002) relatam um experimento utilizando várias medidas de textura com janelas 5x5, 10x10 e 20x20 aplicadas sobre a banda pancromática, sendo que cada imagem resultante foi incluída na classificação com o algoritmo da máxima verossimilhança. Cada classificação foi efetuada considerando cinco bandas, quatro que resultaram da fusão das bandas pancromática e multiespectral do Ikonos, e a outra correspondente à textura. As classes de informação foram “ruas”, “edificações”, “gramado”, “árvores”, “solo exposto”, “água” e “sombas”. A medida de textura mais significativa para as classes “gramado” e “árvore” foi a entropia, que corresponde a uma medida do grau de aleatoriedade. A entropia foi calculada utilizando máscaras 10x10 e 20x20, elevando a exatidão média da classificação para as classes “gramado” e “árvore” em 10% quando comparado à classificação efetuada apenas com os dados espectrais. Por outro lado, as medidas de textura não tiveram aumento significativo da exatidão da classificação para as classes “ruas” e “edificações”, sendo que o melhor resultado correspondeu a um aumento de apenas 1,5%.

Sintetizando, foi constatado a partir dos experimentos relatados que a classificação de áreas urbanas com base no píxel, considerando apenas a informação espectral, leva à ocorrência de confusão na discriminação de algumas classes como entre gramado e árvores, e entre telhados e ruas. Alguns problemas podem ser minimizados com o uso da informação adicional proporcionada pelo laser scanner,

possibilitando a discriminação entre objetos com diferentes elevações. Outro problema comum em áreas urbanas é a presença de sombras. Uma possibilidade para lidar com a presença de sombras é segmentar as regiões de sombra para então fazer a classificação separadamente das áreas de sombra e iluminadas. Outra possibilidade é a utilização de textura como informação adicional na classificação com base no pixel.

#### 2.4.2 Classificação com base em regiões

Para a classificação com base em regiões, é necessário obter a partir da imagem original um conjunto de regiões uniformes, que serão alvo do processo de classificação. Esta divisão da imagem em regiões uniformes pode ser obtida usando técnicas de segmentação.

O objetivo básico do processo de segmentação é o de gerar regiões significativas. A forma tridimensional de cada objeto do mundo real é representada por uma região bidimensional correspondente na imagem. Estas regiões são usadas para identificar os objetos com base nas propriedades presentes na imagem.

Segmentação é o processo de dividir completamente a imagem em regiões não superpostas. Algoritmos de segmentação criam regiões que podem então ser utilizadas no estágio de classificação. A premissa é a de que cada uma das regiões corresponde exatamente a uma e somente uma classe de objeto.

Diferentes algoritmos de segmentação têm sido desenvolvidos nos campos de Reconhecimento de Padrões e Visão Computacional, e aplicados com sucesso a disciplinas como medicina e telecomunicações. Entretanto, devido à complexidade dos modelos de objetos e a heterogeneidade dos sensores, sua aplicação em sensoriamento remoto e fotogrametria tem sido limitada a implementações com propósito especial. Com o advento de dados de alta resolução, o interesse geral em métodos de segmentação foi reativado (SCHIEWE, 2002).

Uma outra técnica que busca gerar objetos utilizando informações espectral e espacial é a segmentação multi-resolução, implementada no software eCognition.



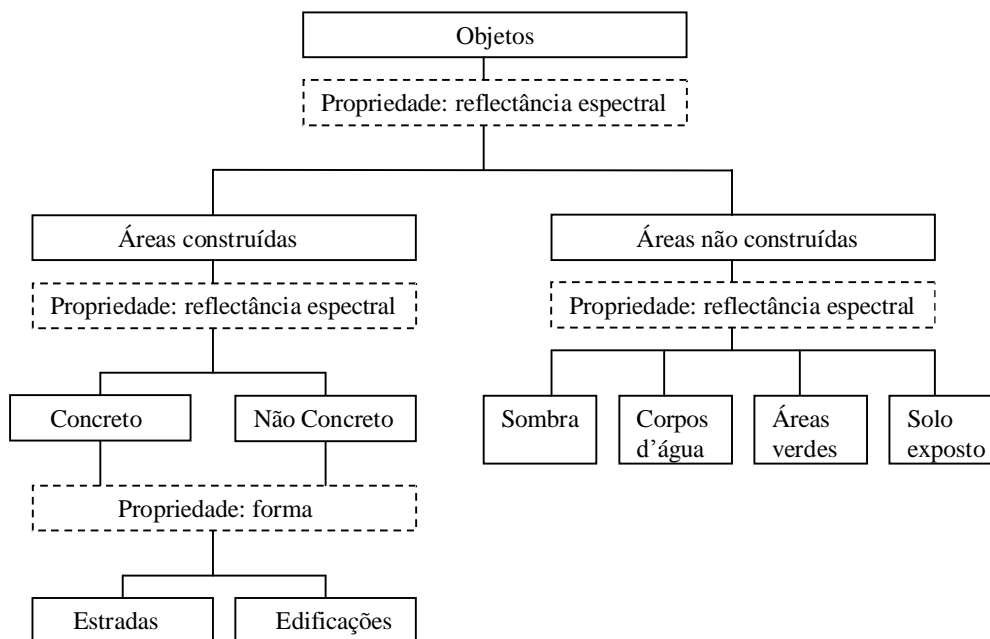
Segundo BENZ et al (2004), a segmentação multi-resolução inicia com um pixel formando uma região, sendo que, a cada etapa, um par de objetos é fundido para formar um objeto maior, com base num critério de homogeneidade. Ao mesmo tempo, busca-se alcançar uma heterogeneidade mínima no processo de agregação. O resultado do processo de segmentação leva a objetos primitivos como uma primeira aproximação a objetos do mundo real. O analista estabelece os pesos a serem considerados nos critérios de semelhança, especificando valores para forma e cor, bem como um parâmetro de escala. O parâmetro de escala influencia o tamanho médio do objeto, sendo que um valor de escala maior conduz a objetos maiores. Os critérios de semelhança e do parâmetro de escala devem ser escolhidos com base nas resoluções espacial (forma) e espectral (cor) da imagem. Os objetos gerados na imagem segmentada estão inter-relacionados, de modo que cada objeto da imagem possui um contexto (vizinhança). O aspecto semântico de cada objeto no terreno passa a ser avaliado de acordo com suas propriedades geométricas (posição, tamanho e outras propriedades derivadas) e temáticas. A hierarquia de objetos resultante da segmentação multi-resolução é a base do conhecimento para a classificação dos objetos.

Com relação à análise multiescala dos objetos, pequenas regiões podem ser agregadas para formar uma região maior construindo uma hierarquia semântica que se assemelhe mais à aparência do objeto real na imagem. De modo similar, um objeto grande pode ser dividido em objetos menores. No eCognition, esta modelagem pode ser realizada criando uma rede hierárquica de regiões da imagem usando segmentação multiescala. Os segmentos de nível mais alto representam objetos de pequena escala, enquanto os segmentos de nível mais baixo representam objetos de grande escala. Isto também significa que os nomes das classes e a hierarquia de classes são representativas com relação a dois aspectos: o mundo real e os atributos fisicamente mensuráveis dos objetos na imagem.

A abordagem da classificação com base no objeto também encontra problemas quando aplicada a áreas urbanas. DUTTA e SERKER (2004) relatam a classificação

de uma imagem multiespectral Quickbird obtida com visada nadiral, utilizando características espectrais e de forma na segmentação. Foram definidas sete classes de cobertura do solo: concreto, telhado não concreto, áreas verdes, solo exposto, corpos d'água e asfalto. O objetivo deste estudo foi realizar um inventário de edificações, o que foi conseguido com exatidão de 90%, sendo que a exatidão total da classificação foi de 85%. Muitas feições urbanas estavam completamente ou parcialmente cobertas por árvores e sombras, prejudicando os resultados da classificação. Foi verificado que edificações, ruas e outras feições são claramente visíveis e identificáveis na imagem Quickbird; porém a forma destas feições na imagem classificada não foi totalmente coincidente com a obtida mediante a digitalização a partir da imagem. As classes foram definidas conforme a Figura 2.6.

FIGURA 2.6 - REDE SEMÂNTICA PARA AS CLASSES DEFINIDAS POR DUTTA E SERKER (2004).



#### 2.4.3 Comparações entre as abordagens com base no pixel e com base em regiões

Nesta seção são apresentadas comparações entre as duas abordagens, para imagens de sensor aerotransportado e imagem Ikonos, e os procedimentos indicados

para correção dos erros de classificação. THOMAS et al (2003) classificaram imagens multiespectrais com quatro bandas (azul, verde, vermelho e infravermelho próximo) adquiridas com o scanner ADAR 5500 com resolução espacial entre 1 e 2m. O objetivo foi determinar as superfícies impermeáveis da cidade de Scottsdale, Arizona, EUA. Foi efetuada uma segmentação inicial com 50 classes espectrais, sendo comparados os segmentos com as assinaturas espectrais das classes desejadas, sendo os segmentos divididos em puros e misturados. Na segunda fase, foram usados *layers* disponíveis em Sistemas de Informações Geográficas (uso do solo, eixos ruas, modelo digital de elevação, zoneamento) além de ortofotos para a modelagem espacial visando reclassificar os pixels mistura utilizando regras como:

*Para cada pixel*

*Se o pixel é mistura pavimento/solo exposto*

*Se o pixel está dentro da área industrial ou comercial*

*Então o pixel é classificado como pavimento de acordo com este modelo*

*Ou SE o pixel está dentro da área residencial*

*Então o pixel é classificado como solo exposto segundo este modelo*

Alternativamente, os autores realizaram segmentação com o software eCognition. Tomando segmentos como amostras, foi construída uma árvore de decisão utilizando o pacote estatístico SPlus. A exatidão da classificação foi maior para a modelagem espacial utilizando informação contextual (81%), enquanto que a abordagem com a segmentação e classificação com a árvore de decisão teve exatidão de 70%. No entanto, os autores consideram que a abordagem da segmentação e classificação incorporando a árvore de decisão tem a vantagem de ganho significativo em termos de tempo, enquanto a modelagem espacial requer que um analista teste e implemente modelos complexos para resolver formas específicas de confusão espectral.

VAN DE VOORDE et al (2004) compararam técnicas de classificação com

base no pixel e com base em regiões para nove tipos de cobertura do solo, numa área teste da cidade de Ghent, na Bélgica. Foi utilizada uma imagem Ikonos híbrida (resultante da fusão entre as bandas multiespectrais e pancromática) ortorretificada. Eles aplicaram uma abordagem baseada em conhecimento para a pós-classificação do resultado da classificação com base no pixel, usando um MDS como dado auxiliar. Para a classificação com base no pixel, foram utilizadas as abordagens da máxima verossimilhança e uma rede neural; a abordagem orientada a objeto foi implementada no software eCognition. Foram utilizadas as bandas multiespectrais híbridas, pancromática e índice normalizado de diferença de vegetação (NDVI) e, no caso da utilização da rede neural, também foram utilizadas imagens de textura com base nas matrizes de co-ocorrência obtidas a partir da banda pancromática. A tabela 2.4 mostra o índice Kappa para as classificações com rede neural (com base no pixel) e com base em regiões:

TABELA 2.4 - COMPARATIVO ENTRE AS CLASSIFICAÇÕES COM BASE NO PIXEL E COM BASE EM REGIÕES (VAN DE VOORDE ET AL, 2004).

Classe de cobertura do solo	Kappa (rede neural)	Kappa (região)
Superfície vermelha (%)	0,83	0,88
Vidro ou plástico (%)	0,55	0,58
Água (%)	0,85	0,88
Gramma (%)	0,94	0,85
Árvores e shrub (%)	0,88	0,81
Cinza claro (%)	0,94	0,97
Cinza médio (%)	0,81	0,81
Cinza escuro (%)	0,83	0,84
Sombra (%)	0,84	0,78

Na abordagem orientada a regiões, a banda pancromática foi segmentada e classificada juntamente com as bandas multiespectrais e o NDVI. Também foram utilizadas bandas adicionais, uma correspondendo à intensidade e três razões, da forma:

$$r = R / (R + G + B) \quad (2.1)$$

$$g = G / (R + G + B)$$

$$b = B / (R + G + B)$$

$$e \quad \text{Intensidade} = r + g + b$$

Assim, a intensidade corresponde à soma dos valores médios de uma região em todas as bandas e a razão é o valor médio de uma região dividido pela soma dos valores médios em todas as bandas.

Uma explicação para o baixo valor de Kappa na tabela 2.4 para as classes vidro/plástico é provavelmente o fato de que grama e plástico não tem assinaturas típicas por causa do ângulo de incidência do Sol, resultando em confusão com outras classes. Com os testes realizados, VAN DE VOORDE et al (2004) concluem que não é possível afirmar que a abordagem orientada a regiões é melhor do que a abordagem com base no pixel. Eles consideram que, mesmo visualmente, não se pode afirmar qual abordagem tem melhor desempenho. Uma vez que os mapas temáticos resultantes da classificação dos tipos de superfícies urbanas não podem ser diretamente usados para o planejamento ou gerenciamento urbano, a informação de elevação (DSM) foi utilizada para identificar edificações e superfícies artificiais e foram definidas regras para efetuar a reclassificação. Tais regras tem o seguinte aspecto:

*(1) SE região = “vidro no nível de edificação”*

*E vizinhança da região = “classe cinza no nível das edificações”*

*ENTÃO adicionar todos os pixels da região a “classe cinza no nível de edificações”*

*(2) SE região = “sombra no nível de terreno”*

*E vizinhança da região = “arbusto no nível de terreno”*

*ENTÃO adicionar todos os pixels da região a “arbusto no nível de terreno”*

*SE segunda classe mais proeminente for arbusto*

A primeira regra reclassifica vidro e superfícies refletoras acima de 6 metros como telhado cinza. A segunda regra reduz a quantidade de sombra de árvores em regiões de arbusto. Uma regra similar é aplicada para remover sombra de superfícies cinza no nível do terreno. Comparando estes resultados com os da interpretação visual da imagem, VAN DE VOORDE et al (2004) constataram que, em alguns casos, a forma e a extensão das edificações não estão corretas e que isto se deve a erros no DSM nas proximidades de bordas das edificações.

Com base nestes experimentos, pode-se considerar que não existe uma abordagem de classificação ótima para áreas urbanas. A classificação com base em regiões também é afetada pela presença de sombras, e existe dificuldade na segmentação de feições como ruas e edificações. A informação altimétrica pode ser usada para separar classes que ocorrem ao nível do solo e acima do solo, mas erros existentes no MDS podem alterar a forma e extensão de edificações e outras classes de interesse. O ângulo de incidência da luz solar também pode alterar a assinatura espectral das classes.

## 2.5 FUSÃO DE DADOS

Numa imagem multiespectral, cada banda representa a distribuição espacial de energia referente a uma parcela da superfície terrestre, para determinados intervalos de comprimentos de onda do espectro eletromagnético. Normalmente, outras fontes de dados estão também disponíveis para as regiões de interesse, incluindo cartas topográficas, mapas de propriedades, mapas geológicos e outros. Estas fontes de dados espaciais contêm informação não disponível na imagem multiespectral e a combinação de dados multiespectrais e dados representados em mapa permite inferências sobre regiões da superfície terrestre que não são possíveis quando se utilizam dados de uma única fonte (RICHARDS e JIA, 1999, p.30).

Para efetuar a análise de bases de dados espaciais mistas, que podem consistir de imagens de satélite, dados topográficos ou outros dados disponíveis em

sistemas de informações geográficas, a referência geográfica deve ser comum. A rotulação de dados pela realização de inferência a partir de diversas fontes de dados é chamada fusão de dados (RICHARDS e JIA, 1999, p 293).

A fusão pode ser realizada em diferentes níveis, por exemplo, na medição, nos atributos, regras ou mesmo níveis de decisão (KIEMA e BÄHR, 2000). O método de fusão é influenciado por vários fatores incluindo: o tipo de aplicação em estudo, a estrutura dos dados bem como a característica da imagem que devem ser realçadas ou preservadas. Uma possibilidade para a fusão é a utilização de métodos baseados em conhecimento ou de sistema com base em regras.

## 2.6 REPRESENTAÇÃO DO CONHECIMENTO

Num procedimento de classificação convencional, o conhecimento é fornecido pelo usuário em relação ao algoritmo a ser utilizado e, mais particularmente, na definição das amostras para treinar o classificador. No contexto da inteligência artificial, o conhecimento pode ser definido como a informação armazenada ou os modelos utilizados por uma pessoa ou máquina para interpretar, predizer, e responder apropriadamente ao mundo exterior (FISCHLER e FIRSCHEIN, 1987, p.64).

A questão da representação, ou de como capturar, da melhor forma possível, os aspectos críticos da atividade inteligente para uso num computador tem sido um tema constante ao longo da história da inteligência artificial (LUGER, 2004, p196). Os médicos são capazes de diagnosticar doenças porque possuem conhecimento extenso de medicina, além de suas habilidades gerais de solução de problemas. Os arquitetos projetam casas porque eles têm conhecimento de arquitetura. As heurísticas utilizadas no diagnóstico médico são diferentes das heurísticas para se projetar um prédio.

A representação de uma situação (ou objeto, ou problema) é uma tradução de uma situação em um sistema consistindo de um vocabulário que nomeia coisas e relações, operações que podem ser realizadas sobre estas coisas, e fatos e restrições sobre estas coisas. A representação requer convenções notacionais (sintaxe), o

significado dos objetos e relações especificadas (semântica) e um modelo computacional especificando como os objetos e relações são manipulados de acordo com convenções semânticas (DEAN et al, 1995, p.11).

A representação é uma maneira de seletivamente e criativamente modelar o mundo. A representação funciona como um substituto para o objeto, uma alternativa para as coisas que existem no mundo real, ou seja, substituem a interação direta com o mundo. Quando uma certa forma de representação é selecionada, isto implica em uma série de decisões sobre como e o que será considerado o mundo real, pois cada forma de representação realça determinados aspectos da realidade enquanto dissimula outros.

Uma porção significativamente da pesquisa em inteligência artificial está relacionada com a criação e estudo de propriedade de representações simbólicas. Segundo FISCHLER e FIRSCHEIN (1987), as principais representações são:

- Espaço de características (ou espaço de decisões). Um espaço de características é formado pela atribuição de uma medida relacionada ao problema a cada eixo de um espaço multidimensional.

- Grafo relacional/rede semântica. Uma estrutura de árvore ou grafo é usada tipicamente para descrever relações entre objetos, frequentemente com o propósito de responder a questões.

- Árvore de decisão. Numa estrutura de árvore típica, cada nó, representando um estado, é conectado a um ou mais estados sucessores. O objetivo é o de percorrer a árvore do estado inicial até um estado final desejado.

- Quadros ou *frames*. Um *frame* é um modo de representar conhecimento sobre objetos ou eventos comuns a uma situação particular. Os elementos de uma determinada situação são armazenados como “escaninhos” de um quadro.

- Lógica. O cálculo proposicional e de predicados são formalizações do processo de inferir nova informação a partir de fatos existentes.

- Representações procedimentais. O conhecimento sobre o mundo pode ser formulado em termos de procedimentos que permitem que tarefas específicas sejam executadas.



- Sistemas de produção. São regras da forma SE condição A for satisfeita, então se segue a consequência B.

- Representações isomórficas/icônicas/analogias. São representações para as quais existe uma relação estrutural direta com algumas propriedades do domínio que está sendo representado.

A representação mais apropriada depende da tarefa em questão e das rotinas disponíveis para fazer uso da informação codificada em uma determinada descrição (DEAN et al, 1995, p.10).

## 2.7 APRENDIZADO

Segundo LUGER (2004), aprendizado é “qualquer mudança num sistema que melhore o seu desempenho na segunda vez que ele repetir a mesma tarefa, ou uma outra tarefa sobre a mesma população”. Segundo DEAN et al (1995), o aprendizado ocorre quando o sistema adquire novo conhecimento a partir de seu ambiente ou quando ele organiza seu conhecimento para fazer melhor uso deste.

A tarefa de construir definições de classe a partir de exemplos é chamada de aprendizado de conceitos, ou indução. A partir de exemplos de um determinado conceito como “gato”, “doença da soja” ou “bom investimento em ações”, busca-se inferir uma definição que permitirá à máquina de aprendizagem reconhecer futuras ocorrências daquele conceito, aprendendo uma generalização a partir de um conjunto de exemplos. O aprendizado supervisionado depende de exemplos de treinamento previamente classificados.

A abordagem simbólica modela o aprendizado como a aquisição de conhecimento do domínio explicitamente representado. Com base na sua experiência, a máquina de aprendizagem constrói ou modifica expressões numa linguagem formal, e retém este conhecimento para uso futuro. As abordagens neurais ou conexionistas não aprendem adicionando representações à base de conhecimento; em vez disso, as redes neurais aprendem modificando os pesos associados às conexões internas

definidas na sua estrutura, de modo a se adaptar às contingências do mundo.

## 2.8 ÁRVORE DE DECISÃO

Por meio de particionamento recursivo do domínio de definição das variáveis preditoras, o conhecimento sobre o problema pode ser representado por meio de uma estrutura de árvore de decisão. A figura 2.7 mostra dois padrões caracterizados por duas variáveis denotadas por  $X_1$  e  $X_2$  e uma variável classe  $C$  com dois valores possíveis, A e B. Uma possível representação do conhecimento subjacente ao domínio pode ser vista por meio da árvore de decisão da figura 2.8.

FIGURA 2.7 - ESPAÇO DE CARACTERÍSTICAS COM VARIÁVEIS ( $X_1, X_2$ ) E VALORES (A,B).





FIGURA 2.8 - ÁRVORE DE DECISÃO CORRESPONDENTE AO ESPAÇO DE CARACTERÍSTICAS DA FIGURA 2.7.



As variáveis estão representadas na árvore de decisão como círculos, e as folhas da árvore são representadas por retângulos nos quais estão inseridos os valores das classes. A árvore de classificação da Figura 2.8 tem para todos os ramos uma profundidade 2, sendo que este conceito de profundidade proporciona uma idéia da complexidade da árvore de classificação. Por outro lado, neste exemplo não existe ruído no sentido de que as folhas são puras ao conter tão somente padrões de um determinado tipo. Cada caminho da raiz até a folha corresponde a uma regra de decisão ou classificação. Assim, a árvore de classificação pode ser expressa por meio de um conjunto de regras:

*Regra 1:* se  $X_1 > 1,5$  então  $C = B$

*Regra 2:* se  $1 < X_1 < 1,5$  então  $C = A$

*Regra 3:* se  $X_1 < 1$  e  $X_2 < 1$  então  $C = A$

*Regra 4:* se  $X_1 < 1$  e  $X_2 > 1$  então  $C = B$

Num procedimento tradicional de classificação supervisionada, os pixels são analisados com base nas chamadas assinaturas das classes. Métodos estatísticos utilizam a suposição de que as probabilidades de pertinência às classes podem ser modelada a partir de uma função densidade de probabilidade específica. Na maioria dos casos, é escolhida a distribuição Gaussiana caracterizada pelos vetores de médias das classes e pelas matrizes covariância das classes. A suposição de que os dados de cada classe seguem uma distribuição normal multivariada restringe a análise aos dados nas escalas intervalar ou razão. Já os métodos conexionistas não fazem suposições sobre a distribuição estatística de frequências dos dados ou sobre as escalas de medidas das características que são usadas na análise, mas o conhecimento gerado na fase de treinamento é implícito.

Segundo BONHAM-CARTER (1996), as árvores de decisão são uma das ferramentas utilizadas para representar conhecimento em sistemas especialistas. Compreendem não apenas uma base de conhecimento de regras, mas também

constituem um ambiente de decisão que pode ser representado numa linguagem e aplicado para alocar objetos a classes com base em seus atributos. Vários algoritmos de indução de árvores de decisão têm sido desenvolvidos e melhorados nos últimos anos, como os algoritmos ID3, C4.5, QUEST e CART (PAL e MATHER, 2003). Entretanto, os classificadores baseados em árvores de decisão não têm sido amplamente utilizados pela comunidade de sensoriamento remoto como é o caso dos métodos estatísticos ou conexionistas/neurais.

As vantagens de árvores de decisão incluem a capacidade de lidar com dados que estão em diferentes escalas de medidas, não serem necessárias suposições sobre as distribuições de frequência dos dados em cada uma das classes, a flexibilidade e a capacidade de lidar com relações não lineares entre atributos e classes (PAL e MATHER, 2003). Também, o analista pode interpretar uma árvore de decisão, uma vez que é gerado conhecimento simbólico, diferentemente de outras metodologias de aprendizagem como, por exemplo, redes neurais.

Árvores de decisão consistem de classificadores conectados (ou nós de decisão) que executam a classificação da imagem. Partindo de um nó (um teste inicial), são abertos caminhos a novos testes (nós) cada vez mais específicos, até chegar a uma conclusão a respeito da classificação do objeto no topo da árvore.

O tipo mais simples é uma árvore binária, em que cada componente ou nó realiza uma segmentação dos dados em apenas uma dentre duas possíveis classes, ou grupos de classes. A idéia deste tipo de classificador consiste em discriminar seqüencialmente cada uma das classes, de acordo com a banda ou as bandas que permitam mais claramente a sua separação das demais classes.

A criação de uma árvore de decisão envolve três tarefas: encontrar a estrutura ótima para a árvore, escolher o subconjunto ótimo de características para cada nó, e selecionar a regra de decisão a ser usada em cada nó (RICHARD e JIA, 1999). Uma estrutura otimizada pode visar uma taxa de erro mínima, um número mínimo de nós, ou um percurso mínimo para decidir como dividir classes em cada nó.

### 2.8.1 Algoritmo ID3

O algoritmo ID3 foi desenvolvido por Quinlan em 1986, e é um dos algoritmos de árvores de decisão mais populares. Este algoritmo induz conceitos a partir de exemplos e, segundo LUGER (2004), é particularmente interessante pela sua representação do conhecimento aprendido, sua abordagem para o gerenciamento da complexidade, sua heurística para selecionar conceitos candidatos e seu potencial para lidar com dados com ruído.

Utilizando uma amostra de membros das categorias-alvo classificadas corretamente, o algoritmo ID3 constrói árvores de decisão de cima para baixo (“*top-down*”). Para uma determinada propriedade, o conjunto de exemplos de treinamento é dividido em subconjuntos disjuntos, onde todos os exemplos numa partição têm um valor comum para esta propriedade. O ID3 seleciona uma propriedade para testar no nó corrente da árvore e usa este teste para dividir o conjunto de exemplos: o algoritmo constrói, recursivamente, uma subárvore para cada partição. Este processo continua até que todos os membros da partição estejam na mesma classe; esta classe se torna um nó folha da árvore.

No algoritmo ID3, o ganho de informação é a medida estatística que está na base da construção da árvore de decisão. A teoria da informação de Shannon fornece uma base matemática para medir o ganho de informação. O ganho de informação é uma medida de quão bem se pode discriminar instâncias de classes usando um determinado atributo como separador. Associado ao conceito de ganho de informação está o conceito de entropia, que é uma medida de homogeneidade.

Para um conjunto de várias instâncias  $S$ , e um conjunto de  $n$  classes  $C = \{C_1, \dots, C_n\}$ , sendo  $p_i$  a proporção de instâncias no conjunto  $S$  pertencentes à classe  $i$ , a entropia do conjunto  $S$  é expressa como:

$$\text{Entropia}(S) = - \sum_{i=1}^n p_i \log_2(p_i) \quad (2.2)$$

A entropia atinge valor máximo igual a  $\log_2 n$ , quando  $p_1 = p_2 = \dots = p_n = 1/n$ , expressando a existência de homogeneidade. A medida de ganho de informação tem relação com a redução esperada na entropia se as instâncias no conjunto  $S$  forem separadas com um determinado atributo  $A$  das instâncias de  $S$ , com  $\text{Dominio}(A) = \{v_1, v_2, \dots, v_r\} = V$ . Considerando que  $v \in V$  separa um subconjunto de elementos de  $S$ , e denominando esse subconjunto por  $S_v$ , a entropia deste novo conjunto é representado por  $\text{Entropia}(S_v)$ . Realizando esta operação para cada elemento de  $V$ , pode-se calcular o quanto é esperado que seja reduzida a entropia. O ganho de informação do atributo  $A$  é dado por:

$$\text{Ganho}(S,A) = \text{Entropia}(S) - \sum_{v \in V} \frac{|S_v|}{|S|} \text{Entropia}(S_v) \quad (2.3)$$

O “melhor” atributo é aquele que proporciona o maior ganho de informação, sendo reduzida a entropia à medida que são divididos as instâncias presentes no conjunto  $S$ .

Um dos problemas na indução de árvores de decisão é o chamado problema de “*overfitting*”, isto é superadaptação da árvore aos dados de treino, obtendo um desempenho quase perfeito nesses, mas um desempenho pobre para novos dados. Isto pode ter origem na existência de ruído nos dados, devido a valores errados dos atributos ou das classes, ou devido à existência de um conjunto de atributos inadequado ou insuficiente. As extensões e desenvolvimentos ao algoritmo ID3, consideram estes problemas, bem como outros de natureza prática e que serão referidos a seguir.

### 2.8.2 Algoritmo C4.5 / C5

O algoritmo C4.5 também desenvolvido por Quinlan, é um método melhorado em relação ao ID3 que, entre outras melhorias, contorna o problema da

superadaptação utilizando uma estratégia de “*poda da árvore*”. Podar uma árvore, neste contexto, significa reduzir algumas subárvores a folhas, ou de outra forma, um ramo da árvore, a partir de determinado nó é “cortado” (transformado em folha). O corte dum ramo da árvore é guiado por um teste estatístico que considera os erros num nó e a soma dos erros nos nós que descendem desse nó.

Para além do problema da superadaptação, o C4.5 permite lidar com valores numéricos, valores omissos e dados contendo ruído. Uma outra possibilidade disponibilizada por este sistema é a capacidade de validação. Uma última característica deste sistema que merece ser destacada é a possibilidade de gerar regras de decisão a partir de árvores.

O sistema C5 (ou See 5) é a versão comercial para a indução de árvores de decisão, sendo o sucessor do C4.5, mas com melhorias para lidar com as exigências do mundo real. O grande salto foi dado em termos de eficiência, tanto em termos de tempo de processamento quanto na quantidade de memória utilizada (CORDEIRO, 2003).

## 2.9 SISTEMAS ESPECIALISTAS

O conhecimento especialista é uma combinação de um entendimento teórico do problema com uma coleção de regras heurísticas para resolver problemas, que a experiência demonstrou ser efetiva no domínio (LUGER, 2004, p 40). Os sistemas especialistas são construídos através da extração deste conhecimento de um especialista humano, codificando-o de uma forma que um computador possa aplicar a problemas similares.

Os sistemas especialistas (SE's) são concebidos para reproduzir o comportamento de especialistas humanos na resolução de problemas do mundo real, mas o domínio destes problemas é altamente restrito (BITTENCOURT, 2001). Os primeiros SE's que obtiveram sucesso foram os sistemas DENDRAL e MYCIN.

O sistema DENDRAL foi desenvolvido em Stanford no final dos anos 60, e

o MYCIN foi desenvolvido também em Stanford em meados nos anos 70. O sistema DENDRAL é capaz de inferir a estrutura molecular de compostos desconhecidos a partir de dados espectrais de massa e de resposta magnética nuclear. O sistema MYCIN auxilia médicos na escolha de uma terapia de antibióticos para pacientes com bacteremia, meningite e cistite infecciosa, em ambiente hospitalar. Desde então muitos SE's foram desenvolvidos para resolver problemas em muitos domínios diferentes.

Um SE atual apresenta, em geral, uma arquitetura com três módulos: uma *base de regras*, uma *memória de trabalho* e um *motor de inferência* (ver figura 2.9). A base de regras e a memória de trabalho formam a chamada *base de conhecimento* do SE, onde está representado o conhecimento sobre o domínio. O motor de inferência é o mecanismo de controle do sistema que avalia e aplica as regras de acordo com as informações da memória de trabalho.

A memória de trabalho de SE's respeita um método de representação de conhecimento. A base de regras contém condições que representam “perguntas” à representação de conhecimento da memória de trabalho.

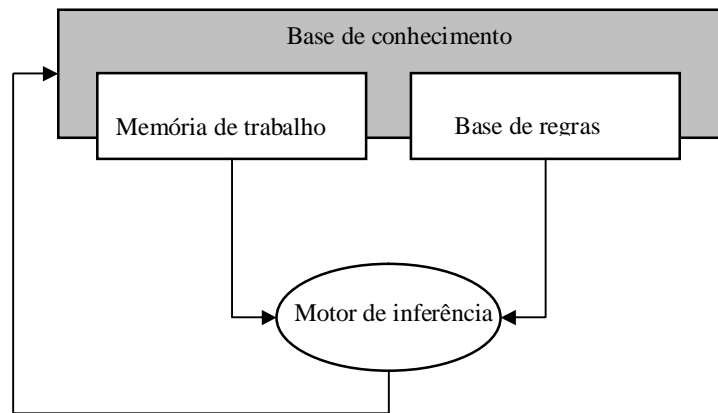
O motor de inferência controla a atividade do sistema. Esta atividade ocorre em ciclos, cada ciclo consistindo de três fases:

1. Correspondência de dados, onde as regras que satisfazem a descrição atual são selecionadas.
2. Resolução de conflitos, onde as regras que serão realmente executadas são escolhidas dentre as regras que foram selecionadas na primeira fase, e ordenadas.
3. Ação, a execução propriamente dita das regras.

As principais características do motor de inferência dizem respeito às seguintes funcionalidades: método de raciocínio, estratégia de busca, resolução de conflito e representação da incerteza.



FIGURA 2.9 - MÓDULOS DE UM SISTEMA ESPECIALISTA.



Existem basicamente dois modos de raciocínio aplicável a regras: encadeamento *progressivo* ou encadeamento para a frente (do inglês “forward chaining”), e encadeamento *regressivo* ou encadeamento para trás (do inglês “backward chaining”). No encadeamento progressivo, também chamado encadeamento dirigido por dados, a parte esquerda da regra é comparada com a descrição da situação atual, contida na memória de trabalho. As regras que satisfazem a esta descrição têm sua parte direita executada, o que, em geral, significa a introdução de novos fatos na memória de trabalho. No encadeamento regressivo, também chamado encadeamento dirigido por objetivos, o comportamento do sistema é controlado por uma lista de objetivos. Um objetivo pode ser satisfeito diretamente por um elemento da memória de trabalho, ou podem existir regras que permitam inferir algum dos objetivos correntes, isto é, que contenham uma descrição deste objetivo em suas partes direitas. As regras que satisfazem esta condição têm as instâncias correspondentes às suas partes esquerdas adicionadas à lista de objetivos correntes. Caso uma dessas regras tenha todas as suas condições satisfeitas diretamente pela memória de trabalho, o objetivo em sua parte direita é também adicionado à memória de trabalho. Um objetivo que não possa ser satisfeito diretamente pela memória de

trabalho, nem inferido através de uma regra, é abandonado. Quando o objetivo inicial é satisfeito, ou não há mais objetivos, o processamento termina.

O tipo de encadeamento normalmente é definido de acordo com o tipo de problema a ser resolvido. Problemas de planejamento, projeto e classificação tipicamente utilizam encadeamento progressivo, enquanto problemas de diagnóstico, onde existem apenas algumas saídas possíveis mas um grande número de estados iniciais, utilizam encadeamento regressivo (BITTENCOURT, 2001, p 272).

Uma vez definido o tipo de encadeamento, o motor de inferência necessita ainda de uma estratégia de busca para guiar a pesquisa na memória de trabalho e na base de regras. Ao terminar o processo de busca, o motor de inferência dispõe de um conjunto de regras que satisfazem à situação atual do problema, o chamado *conjunto de conflito*. Se esse conjunto for vazio, a execução é terminada; caso contrário, é necessário escolher que regras serão realmente executadas e em que ordem.

Os domínios adequados à representação de SE's se caracterizam por não serem modelados por uma teoria geral, o que implica descrições incompletas, inexatas ou incertas. Os métodos para o tratamento da incerteza atribuem aos fatos e regras uma medida numérica que represente de alguma forma a "confiança" do especialista.

A chave para o desempenho de um SE está no conhecimento armazenado em suas regras e em sua memória de trabalho. Este conhecimento deve ser obtido junto a um especialista humano do domínio e representado de acordo com regras formais definidas para a codificação de regras no SE em questão.

Atualmente, os SE's são desenvolvidos em geral a partir de arcabouços ou esqueletos de sistemas especialistas, ou ferramentas que suportam todas as funcionalidades de um SE, mas a base de conhecimentos e os dados específicos do caso estão vazios e devem ser acrescentados para uma nova aplicação. A existência destes arcabouços facilitou bastante a implementação de SE's e foi um dos fatores responsáveis por sua disseminação.

## 2.10 SISTEMAS COM BASE EM REGRAS

Sistemas baseados em regras são viáveis para problemas para os quais o conhecimento na área do problema pode ser escrito na forma de regras SE-ENTÃO e para as quais a área do problema não é grande (FREEMAN-HARGIS, 2005). Para criar um sistema com base em regras para um determinado problema, deve-se ter:

1. Um conjunto de fatos para representar a memória de trabalho inicial. Isto pode ser qualquer informação relevante relacionado ao estado inicial do sistema.
2. Um conjunto de regras. Isto deve incluir toda e qualquer ação que deve haver no escopo do problema.
3. Uma condição que determine que uma solução foi encontrada ou que nenhuma existe.

O sistema baseado em regras usa uma técnica simples: consiste em uma base de regras, a qual contém todo o conhecimento apropriado codificado em regras SE-ENTÃO, e uma memória de trabalho, a qual pode ou não inicialmente conter dados, afirmações ou conhecimento inicial. O sistema examina a condição SE de todas as regras e determina um subconjunto, o *conjunto de conflito*, de regras cujas condições são satisfeitas com base na memória de trabalho. Deste conjunto de conflito, uma das regras é disparada. A escolha da regra a ser disparada é baseada na estratégia de resolução de conflito. Quando a regra é disparada, as ações especificadas na cláusula ENTÃO são realizadas. Estas ações podem modificar a memória de trabalho, a própria base de regras, ou outra especificação incluída pelo programador do sistema. O *loop* de disparar regras e realizar ações continua até que uma das condições seja encontrada: não existem mais regras cujas condições sejam satisfeitas ou é disparada uma regra cuja ação especifica que o programa deve terminar.

### 2.10.1 Representação da incerteza

Qualquer decisão dentro do processo de inferência está associada a um certo

grau de incerteza, assim como também os próprios dados de entrada apresentam incerteza. Por este motivo, o resultado da inferência deve ser avaliado em função da incerteza associada à série de decisões tomadas.

O que se convencionou chamar de tratamento da incerteza endereça imperfeições da informação, como imprecisão, conflito ou ignorância parcial. De acordo com RABUSKE (1995, p 205), o tratamento da incerteza pode ser requerido “em diversas etapas do manejo do conhecimento, como na coleta da informação, na definição dos elementos do conhecimento, na combinação dos elementos entre si (incerteza nas premissas), na forma de tirar conclusões (aplicação de uma regra de raciocínio) e na avaliação de uma seqüência de regras ou estruturas (aplicações sucessivas de regras de raciocínio)”.

No contexto das árvores de decisão, a incerteza deve ser associada aos fatos e regras. Podem ocorrer que se chegue a mais do que uma conclusão apenas, cada qual com um determinado grau de certeza. Raciocinar sobre incerteza exige: a) a quantificação da incerteza, e b) método de combinação e propagação da incerteza.

Em sistemas especialistas para diagnóstico médico, como MYCIN, e para prospecção, como PROSPECTOR, as regras tem um significado probabilístico, da forma: “*SE existe uma evidência A e uma evidência B, ENTÃO a hipótese C é verdadeira com certeza de 0,7*” (RICH e KNIGHT, 1994). A probabilidade nestas regras tem o sentido de escore dado por um especialista para indicar a relevância da evidência para uma hipótese ou a crença de que uma certa evidência é verdadeira (FISCHER e FIRSCHEIN, 1987).

## 2.11 SISTEMAS ESPECIALISTAS EM SENSORIAMENTO REMOTO

TSATSOULIS (1993) afirma que existe pouco trabalho combinando sistemas especialistas e aplicações em sensoriamento remoto comparado ao volume da pesquisa na área. Ele agrupou as aplicações de sistemas especialistas em sensoriamento remoto em cinco categorias:

(1) sistemas de auxílio ao usuário – sistemas especialistas para auxiliar no processamento e reconhecimento de padrões;

(2) classificadores – sistemas especialistas para classificar dados de sensores remotos;

(3) sistemas de processamento de baixo nível – sistemas especialistas para processamento de baixo nível; o processamento inicia com a imagem e gera descrições de alto nível, tais como linhas, regiões, cantos e objetos;

(4) sistemas de fusão de dados – sistemas especialistas para a classificação de dados de fontes diferentes e fusão de dados;

(5) aplicações SIG – uso de sistemas especialistas em SIG.

Alguns sistemas especialistas trabalham com base no pixel, isto é, eles aplicam regras a cada pixel da imagem, enquanto outros classificam regiões. Um sistema especialista simples pode utilizar o conhecimento sobre os dados do TM Landsat para classificar vegetação utilizando a regra: *SE a intensidade na banda 4 é maior do que a intensidade nas bandas 3 e 5, ENTÃO é vegetação.*

Um sistema que se enquadra nas categoria 1, 2 e 5 de TSATSOUKIS (1993) é o sistema com base em regras descrito por CHOI e USERY (2004). Tal sistema usa uma abordagem interativa com base em perguntas e respostas, sendo que as regras de inferência têm estrutura de árvore, e a decisão em cada nó da árvore considera os elementos de interpretação visual. O sistema é integrado com SIG, e pode ser usado para fins de mapeamento de dados espaciais.

A arquitetura do sistema compreende três componentes: o sistema especialista, a interface com o usuário e o SIG. O sistema especialista é composto de: base de conhecimento, máquina de inferência, e módulo de aquisição do conhecimento. O conhecimento é armazenado e recuperado usando uma base de dados relacional. O módulo SIG inclui um carregador de dados espaciais, um visualizador, um digitalizador e um exportador de dados espaciais. O módulo SIG foi desenvolvido com ferramentas do MapObjects da ESRI, e o módulo de aquisição do conhecimento, a máquina de inferência e a interface com o usuário foram desenvolvidas com Visual

Basic. A base de dados usa uma estrutura relacional e é implementada em Access (Microsoft).

A base de dados relacional inclui uma tabela para o problema, uma tabela de questões que contém tanto as perguntas quanto às respostas para um problema, e a base de regras. Para cada novo problema, devem ser criadas as três tabelas (problema, questões e base de regras).

No sistema de CHOI e USERY (2004), a construção de regras requer três passos: a construção de uma árvore de decisão, simbolização e a construção das regras. A árvore de decisão é construída usando o conhecimento do especialista no domínio da aplicação. Os elementos de interpretação (tonalidade, textura, padrão, forma, sombra, tamanho e localização) são usados para construir regras com a árvore de decisão. O usuário do sistema, utilizando o módulo SIG, pode digitalizar uma feição durante a interpretação da fotografia aérea. Então, utilizando o sistema especialista, responderá as questões, e com base nas respostas a máquina de inferência sugere a identificação da feição. O nome pode ser associado à feição no arquivo vetorial, e exportado para o formato *shape* utilizando recursos disponíveis no MapObjects.

Segundo TSATSOULIS (1993), a maioria dos sistemas de classificação tem se concentrado em tarefas simples de classificação. Os sistemas especialistas para classificação de imagens podem ser enquadrados em três categorias: sistemas semelhantes à relaxação que iniciam com a classificação de um pixel ou região e aplicam conhecimento para verificação; classificadores com base no pixel que aplicam conhecimento sobre uma pequena vizinhança de um único pixel; e sistemas especialistas que são aplicados em domínios onde existe uma estrutura rígida e modelo que podem ser utilizados para a classificação (por exemplo, redes de drenagem, estradas, áreas urbanas, e assim por diante). Existem poucos sistemas especialistas em domínios onde não existem modelos estruturais claros.

Conforme RICHARDS e JIA (1999), algumas vezes, um pequeno sistema especialista pode realizar um trabalho muito específico muito melhor do que um programa algorítmico. Para o sensoriamento remoto, as técnicas de inteligência

artificial abrem possibilidades não disponíveis aos programas tradicionais, como por exemplo, na integração de dados de vários sensores.

Uma abordagem para melhorar a qualidade da classificação utilizando informações contidas num sistema de informações geográficas é descrita por DESACHY et al (1996). O processo consiste de dois passos:

- efetuar a classificação (supervisionada ou não)
- introduzir o conhecimento e informação não dependente da imagem para melhorar a classificação.

No sistema ICARE (*Image CARTography Expert*), descrito por DESACHY et al (1996), informações numéricas e simbólicas podem ser combinadas. A classificação inicial é efetuada com o classificador da máxima verossimilhança, com a utilização de textura. Na segunda etapa, são utilizadas descrições de melhor localização das classes desejadas e informações como elevações, tipos de solo, proximidade de estradas e rios. O conhecimento é armazenado em uma base de conhecimento como regras com fatores de certeza, e é relativo a classes presentes da imagem. O conhecimento lida com informações existentes ou computáveis a partir de SIG ou da própria imagem. As regras de produção são expressas da forma:

*If class "pines"*  
*Then (south versants)*  
*And (800 < elevation < 1500m).*

A base de fatos contém o conjunto de informações disponíveis para cada pixel (resultado da classificação inicial e as informações do SIG). Um experimento foi realizado com o sistema ICARE para produzir mapa de vegetação para uma região tropical localizada no sul da Índia. As fontes de informação foram: imagem MSS Landsat, modelo digital de elevação, e mapas de estradas, de cidades e de vilas, e o conhecimento sobre a vegetação local. A melhoria em termos de exatidão da classificação é apresentada comparativamente em termos percentuais: exatidão da

classificação convencional em comparação com a análise visual de 58,60%, e a exatidão da classificação com o sistema especialista em comparação com a análise visual de 71,88%.

A incorporação de informação suplementar de SIG e do conhecimento de especialistas são necessárias para melhorar a análise de imagens de sensoriamento remoto. O método usual de aquisição de conhecimento em um formato utilizável pelo computador para construir a base de conhecimento envolve especialistas humanos e engenheiros do conhecimento; o conhecimento deve ser explicitado pelo especialista e o engenheiro traduz o conhecimento do domínio em um formato usável pelo computador e o armazena na base de conhecimento. Uma alternativa, que tem gerado interesse crescente, é a utilização de métodos de indução para a geração de regras, sendo que tais métodos têm apresentado desempenho razoável (HODGSON et al, 2003).

HUANG e JENSEN (1997) utilizaram o algoritmo C4.5 para construir a árvore de decisão. O C4.5 não depende de suposições sobre a distribuição dos valores de atributo ou da independência entre si dos atributos; isto é importante quando da utilização de dados SIG conjuntamente com dados de imagem. Os atributos utilizados foram: imagem multiespectral SPOT, texturas geradas a partir das bandas multiespectrais, mapa de solos, modelo digital de elevação e coordenadas. O sistema com base em regras foi construído com o arcabouço de sistema especialista CLIPS. O resultado da classificação com o sistema com base em regras foi comparado com o resultado da classificação supervisionada tradicional com dados espectrais e de SIG, sendo que a exatidão total foi de 74,16% para o sistema de regras geradas com a árvore de decisão, enquanto que a exatidão total foi de 65,07% para a classificação supervisionada tradicional.

HODGSON et al (2003) utilizaram fotografias aéreas e dados altimétricos obtidos com laser scanner aerotransportado de Richland County, South Carolina, EUA para determinar o percentual de impermeabilização de propriedades. As fotografias aéreas foram digitalizadas e ortorretificadas com resolução espacial nominal de 0,3 m



por 0,3 m. Com os dados obtidos com o laser scanner foi gerado o modelo digital de superfície normalizado (MDSn). Foram efetuadas classificações com base no pixel com o método da máxima verossimilhança e com regras geradas com o algoritmo See5 de árvore de decisão. As mesmas amostras foram utilizadas para as duas abordagens. Também foi realizada a segmentação com o software eCognition, e a posterior classificação destes segmentos com regras geradas com o algoritmo See5. Os autores tinham expectativa de que a abordagem não paramétrica produzisse melhores resultados do que a classificação paramétrica, uma vez que a informação de elevação não apresenta distribuição normal, e também que a classificação com base em regras fosse melhor para a classificação de segmentos do que para a classificação com base no pixel. Entretanto, a abordagem que produziu o melhor resultado foi a classificação com o algoritmo da máxima verossimilhança, seguida da classificação dos segmentos com base em regras. Como problemas percebidos na classificação de imagem de alta resolução são indicados: erros na classificação de pixels correspondentes a sombras, e a grande variação do material dos telhados, que torna difícil a discriminação como uma única classe. Com relação à sombras, houve confusão com a classe água; já em áreas residenciais, os pixels relativos a sombras correspondem a gramado ou calçadas, afetando o cálculo de áreas referentes a superfícies impermeáveis.

Destes experimentos, pode-se considerar que a classificação de imagens com sistemas especialistas depende da separabilidade espectral entre as classes, a qual pode ser afetada pela presença de sombra. As classes que apresentam grande variação intraclasse, como é o caso de telhados, devem ser desmembradas em subclasses considerando os diferentes materiais e cores.

Um grande obstáculo para a utilização de sistemas especialistas em sensoriamento remoto é a explicitação do conhecimento para a construção de bases de conhecimento. Uma possibilidade para a obtenção do conhecimento pode ser a utilização de algoritmos de aprendizado indutivo como as árvores de decisão, sendo que as árvores de decisão podem ser expressas por um conjunto de regras que formam a base de conhecimento de um sistema com base em regras. Outra possibilidade

proporcionada pelos sistemas com base em regras é a integração de informações de diferentes fontes na classificação.

### 3. ÁREA DE ESTUDO E INFRA-ESTRUTURA

Neste capítulo são apresentados os recursos utilizados para o desenvolvimento da pesquisa e os dados utilizados. Os dados correspondem a diferentes extensões espaciais, sendo que a área de estudo foi selecionada como sendo a parcela comum a todas as fontes de dados disponíveis.

#### 3.1 ÁREA DE ESTUDO

A área de estudo corresponde ao Campus Centro Politécnico da Universidade Federal do Paraná. Desta área de estudo têm-se dados de três diferentes fontes:

- carta topográfica do campus na escala 1:2000,
- dados medidos pelo laser scanner,
- imagem Quickbird.

Das medidas efetuadas pelo sistema laser scanner, foram disponibilizadas coordenadas E,N,h de pontos, bem como a intensidade do retorno, correspondentes ao primeiro e último pulso. A imagem Quickbird foi disponibilizada nos modos pancromático e multiespectral.

Nesta área, existem edificações com tamanhos variáveis em planimetria e em elevação, e diferentes tipos de cobertura de telhados. Existe diferença temporal entre o mapeamento (2001), a aquisição da imagem Quickbird (2002) e as medidas do laser scanner (2003). No interior do Campus e na área vizinha, algumas casas foram construídas entre a aquisição da imagem Quickbird e a realização das medidas com o laser scanner. Também ocorreu uma variação no dossel de vegetação registrado pelos dois sensores.

## 3.2 DESCRIÇÃO DOS DADOS

### 3.2.1 Dados laser scanner

Os dados *laser scanner* correspondem ao primeiro e último pulsos adquiridos pelo sensor ALTM 2050, e foram cedidos pelo Instituto de Tecnologia para o Desenvolvimento - LACTEC. O voo foi efetuado em setembro de 2003 com os seguintes parâmetros: altura de voo de 1.000 m; espaçamento entre os pontos medidos de 0,713 m. O sistema foi operado com a frequência de 50.000 pulsos por segundo, ou seja, 50 kHz, registrando aproximadamente 2.500.000 pontos por quilômetro quadrado. O ângulo de varredura foi de  $\pm 10^\circ$ .

As medidas efetuadas pelo ALTM 2050 passaram por três etapas: (a) processamento da trajetória, (b) processamento das coordenadas (X, Y, Z) juntamente com a intensidade de retorno, e (c) transformação de referencial, correção geoidal e projeção cartográfica; uma descrição destas etapas é apresentada por MARTINS et al (2004). O processamento da trajetória foi realizado com os dados provenientes do voo, como: unidade de medida inercial e rastreadores GPS da aeronave e de campo. O processamento das coordenadas do terreno foi realizado com os dados da trajetória calculados na etapa anterior juntamente com os dados de ângulos e distâncias medidas pelo laser provenientes do voo, possibilitando a determinação de coordenadas cartesianas (X, Y, Z) no referencial WGS-84. As coordenadas no referencial WGS-84 foram transformadas para SAD69, utilizando os parâmetros e fórmulas oficiais divulgados pelo IBGE.

Foram disponibilizados pelo LACTEC dois arquivos, um correspondente ao primeiro pulso e o outro ao último pulso, contendo os dados de posição (E, N, h) e Intensidade.

### 3.2.2 Imagem Quickbird

A plataforma do sensor Quickbird II é um satélite de órbita polar, síncrono com o Sol, colocado a 450km de altitude, sendo que a órbita tem inclinação de 98 graus em relação ao plano Equatorial. O satélite foi lançado em outubro de 2001, e pertence à empresa DigitalGlobe.

O sistema Quickbird captura imagens nos modos Pancromático (Pan) e Multiespectral (MS). Os intervalos espectrais correspondentes a cada banda estão apresentados no quadro 1.1. Com a possibilidade de direcionamento do sensor quando da aquisição das imagens, ocorre a variação da resolução espacial entre a visada nadiral e a visada inclinada (“*off-nadir*”). Para o modo pancromático, a resolução espacial é de 0,61m para a visada nadiral e de 0,72 para a visada inclinada; para o modo multiespectral têm-se, respectivamente, 2,44m e 2,88m. Com a possibilidade de inclinação de até 30°, a resolução temporal é de 1 a 3,5 dias para os modos multiespectral e pancromático, respectivamente.

As imagens Quickbird adquiridas com visada inclinada apresentam efeito de perspectiva, fazendo com que os telhados das edificações fiquem deslocados em relação às suas bases. A imagem Quickbird, com as bandas pancromática e as quatro multiespectrais foi cedida à UFPR pela empresa CetilGeo. Esta imagem está no referencial WGS-84, com resolução espacial de 0,7m para a banda pancromática e de 2,8m para as bandas multiespectrais.

#### 3.2.2.1 Fusão das bandas multiespectrais e pancromática

O processo de fusão (“*pan-sharpening*”) visa obter imagens híbridas que combinam a resolução espacial mais refinada da banda pancromática com a informação espectral das bandas multiespectrais. Entre os métodos comumente utilizados, estão aqueles que fazem uma transformação no espaço de cores. Partindo

do sistema RGB original, é obtido um novo espaço de cores com três bandas, duas correspondentes à representações segundo componentes cromáticas, e a terceira banda segundo um eixo acromático. A banda correspondente ao eixo acromático é substituída pela banda pancromática, e se faz a transformação inversa para o espaço RGB. Estes métodos permitem realizar a fusão da banda pancromática com três bandas espectrais.


O método da substituição da componente principal pode ser utilizado quando se tem várias bandas espectrais. Este método utiliza a técnica estatística da transformação em componentes principais, a qual exige três passos: primeiro, a construção da matriz covariância (ou da matriz correlação) das bandas multiespectrais; segundo, a determinação dos autovalores e autovetores desta matriz; e, terceiro, a formação das componentes principais usando os autovetores como peso. A transformação em componentes principais permite obter, a partir das bandas multiespectrais, um novo conjunto de bandas (componentes principais) que são combinações lineares das bandas originais, sendo que no processo de transformação a informação presente nas bandas originais é reorganizada nas diferentes componentes principais.

A primeira componente caracteriza-se por estar orientada segundo a direção de maior variância dos dados originais, apresentando maior contraste do que as demais componentes (GONZALES E WOODS, 2000). A primeira componente então conterá teoricamente a informação que é comum a todas as bandas originais, enquanto outras componentes conterão informações espectrais específicas. Assim, a primeira componente é substituída pela banda pancromática e é efetuada a operação inversa para levar os dados combinados de volta ao espaço da imagem.

As bandas híbridas resultantes do processo de fusão apresentam alteração espectral em relação às bandas originais, sendo que uma medida estatística da semelhança de cada banda híbrida com a respectiva banda original é fornecida pelo coeficiente de correlação. Para imagens Ikonos e Quickbird, o método da substituição da componente principal gera bandas híbridas que apresentam alta correlação com as bandas multiespectrais originais (SCHNEIDER et al, 2003; PINHO et al, 2005). Assim, dispondo das bandas multiespectrais e da banda pancromática, foi efetuado o

processo de fusão pela substituição da componente principal com o software ENVI, gerando quatro bandas híbridas. A figura 3.1 mostra um recorte da composição das bandas 3, 2 e 1 da imagem Quickbird, originais e resultante da fusão com a substituição da componente principal.

FIGURA 3.1 - COMPOSIÇÃO COLORIDAS DAS BANDAS 3, 2 E 1 ANTES E APÓS A FUSÃO.



### 3.2.3 Carta topográfica do Centro Politécnico

A carta plani-altimétrica do Centro Politécnico na escala 1:2000 foi gerada pelo Departamento de Geomática da UFPR, em setembro de 2001. A informação altimétrica presente na carta possibilitou a geração de Modelo Digital de Elevação (MDE).

As etapas para a geração do MDE foram:

- a) extração de coordenadas tridimensionais de pontos a partir do arquivo vetorial;
- b) geração de uma grade regular, interpolando a partir de faces triangulares (os triângulos de Delaunay).

Na etapa (a) foi utilizado o software *DXf2xyz* versão 1.3 disponibilizado pela empresa *Guthrie CAD/GIS Software*. Na etapa (b) foi utilizado o software ENVI para gerar uma grade regular com 0,7 m de espaçamento.

A informação correspondente a ruas e estradas foi retirada da carta planimétrica para ser utilizada durante o processo de classificação com o sistema baseado em regras.

### 3.3 RECURSOS DE HARDWARE E SOFTWARE UTILIZADOS NA PESQUISA

A configuração do hardware utilizado no processamento foi um computador com processador Athlon XP 2.2 e 256Mbytes de memória RAM, com sistema operacional Windows XP. No desenvolvimento do trabalho foram utilizados os softwares Multispec e Matlab; bem como o ambiente de desenvolvimento Java, a ferramenta de *data mining* Weka e o arcabouço de sistema especialista Jess.

#### 3.3.1 Software Multispec

O Multispec é um software para análise de imagens multiespectrais e hiperespectrais, desenvolvido por Larry Biehl e David Landgrebe, da Universidade de Purdue. Este software está disponível na *World Wide Web* desde 1995, e deste então é atualizado periodicamente a cada quatro meses aproximadamente, sendo que, de acordo com BIEHL e LANDGREBE (2002), cerca de 1800 cópias são baixadas a cada ano por universidades, instituições governamentais e comerciais. Existem duas versões do Multispec, uma para Macintosh (mais completa) e outra para Windows. Os recursos para a classificação incluem a determinação do melhor subconjunto de



características espectrais e classificadores supervisionados como ECHO, discriminante linear de Fisher, SAM (*Spectral Angle Mapper*), além do classificador da Máxima Verossimilhança.

Neste trabalho, o Multispec foi utilizado para:

- a aquisição da posição (linha e coluna) das amostras a serem utilizadas para a construção da árvore de decisões com a ferramenta Weka. No Multispec, quando se está no modo de aquisição de amostras para as classes, é gerado um arquivo de projeto; este arquivo, gerado no formato ASCII, contém a informação das coordenadas dos vértices de um retângulo ou polígono correspondente a cada amostra.

- a associação de um mapa de cores à imagem classificada com o sistema com base em regras, e salvar o arquivo no formato TIFF.

### 3.3.2 Software Matlab

O Matlab foi inicialmente desenvolvido nas Universidades do Novo México e Stanford no início dos anos 70, como um pacote para a manipulação de matrizes. Desde então, o Matlab evoluiu e é atualmente um sistema interativo e uma linguagem de programação para efetuar cálculo técnico e científico.

Neste trabalho, foram utilizados recursos do Matlab 6.1 na leitura e gravação de arquivos ASCII, e também ferramentas gerais para leitura e gravação de imagens. Foram desenvolvidos no ambiente Matlab programas para:

- a geração do Modelo Digital de Superfície a partir dos arquivos de coordenadas de pontos gerados com os dados laser scanner;

- a geração da imagem correspondente à intensidade do retorno do laser;

- a ortorretificação da imagem Quickbird e para o tratamento do efeito da oclusão;

- a leitura do arquivo ASCII resultante da classificação com sistema com base em regra e geração da imagem temática que é então salva em arquivo no formato TIFF.

### 3.3.3 Ambiente Java

Java é atualmente uma das linguagens mais populares de desenvolvimento de software (DEITEL e DEITEL, 2003); quando foi anunciada formalmente pela Sun Microsystems em 1995, gerou interesse imediato na comunidade comercial por causa do interesse pela World Wide Web, que estava também no seu início. Java é disponibilizada gratuitamente pela Sun; a ferramenta SDK (*Standard Development Kit*) é composta basicamente por um compilador, um interpretador, um visualizador de *applets*, bibliotecas de desenvolvimento (*packages*), um depurador de programas e diversas documentações.

Uma característica de Java é a possibilidade de criar aplicativos independentes de hardware e sistema operacional. Isto significa que um programa Java pode ser compilado em qualquer sistema e o arquivo binário pode ser executado no mesmo sistema ou em outro – em um Macintosh, Windows, Linux, e outros. O arquivo compilado não é específico a qualquer máquina física, são instruções de máquina para uma máquina virtual e pode ser executado onde quer que a plataforma Java esteja presente, em qualquer sistema operacional subjacente.

Os programas em Java consistem de partes denominadas classes. As classes consistem de métodos que realizam tarefas e retornam as informações ao completarem suas tarefas. Existem ricas coleções de classes em bibliotecas de classes Java, conhecidas como Java APIs (*Application Programming Interfaces* – interfaces de programas aplicativos) desenvolvidos pela Sun, ou por fornecedores independentes de software. Muitas bibliotecas estão disponíveis a partir da Internet como *freeware* ou *shareware*, sendo muitos deles de código-fonte aberto.

Atualmente existem muitas implementações de linguagens de Inteligência Artificial tradicionais para máquinas virtuais Java, e muitos motores de inferência foram implementados em Java. Em 2003 foi aprovada a JSR-94 (*Java Rule Engine API*), que padroniza a API de um motor de inferência, que constitui o coração de um sistema de processamento de regras, sendo que o Jess é a implementação de referência

da JSR-94 (DOEDERLEIN, 2004).

### 3.3.4 Weka

O pacote Weka consiste de uma coleção de algoritmos de aprendizado de máquina para tarefas de mineração de dados (*data mining*), e foi desenvolvida na Universidade de Waikato, na Nova Zelândia. Pode ser usado para aplicar método(s) de aprendizado a um conjunto de dados e analisar a saída para extrair informações a partir dos dados.

O Weka usa arquivos de dados de treinamento onde devem ser explicitados quais atributos são permitidos para uma relação especificada, bem como o tipo de dado de cada atributo (isto é, string ou valor numérico). O Weka pode detectar padrões em dados que podem ser explorados mediante regras. Dos recursos disponíveis, foi utilizado o sistema de aprendizado com o algoritmo C4.5 desenvolvido por Quinlan e implementado em sua versão para Java (no Weka) com o nome J4.8, para gerar árvores de decisão.

### 3.3.5 Arcabouço de sistema especialista Jess

Em 1985, Pesquisadores do *Johnson Space Center da National Atmospheric and Space Administration* americana, a NASA, desenvolveram o sistema especialista CLIPS (C-Language Integrated Production System), implementado em linguagem C. A maior vantagem do CLIPS foi uma implementação de alto desempenho do motor de inferência, utilizando uma linguagem semelhante a LISP, para especificar a base de conhecimento e as regras. Em 1997, Ernest Friedman-Hill, no *Sandia National Laboratories*, também da NASA, reimplementou CLIPS na linguagem Java, denominando *Java Expert System Shell* ou Jess. Este motor de regras de propósito geral é livre para uso acadêmico, mas deve ser licenciado para uso comercial.

Segundo FRIEDMAN-HILL (2004), o Jess pode ser utilizado de duas maneiras. Primeiramente ele pode ser um motor de inferência, ou seja, um tipo especial de

programa que aplica de maneira eficiente regras a dados. Geralmente as regras representam o conhecimento heurístico de um especialista humano em um domínio específico, e a base de conhecimento representa o estado de uma dada situação. Neste caso pode-se dizer que se tem um *sistema especialista*. Mas a linguagem JESS é uma linguagem de programação de propósito geral e pode acessar diretamente todas as classes e bibliotecas JAVA. Assim, o Jess pode ser usado como um ambiente de desenvolvimento de aplicativos genéricos, incorporando componentes de interface gráfica do JAVA. Por outro lado, programas Java podem mandar expressões para serem avaliadas pelo motor de inferência Jess, e Jess pode ser ampliada com novas classes em Java, uma vez que o código-fonte é aberto.

O JESS é basicamente uma biblioteca, e pode inclusive ser embutido em aplicativos para a Internet ou mesmo utilizado como *applet* em uma página *html*. ŠIMIC e DEVEDŽIĆ (2003) descrevem o desenvolvimento de um sistema tutorial inteligente para aplicações na Web, implementado em Java, utilizando o motor de inferência Jess para interpretar a base de conhecimento gerada em CLIPS.

O Jess foi concebido como uma biblioteca que pode ser embutida em software desenvolvido com Java, e vem apenas com uma interface para inserir comandos de linha. Existem alternativas como o editor gráfico *JessWin*, desenvolvido por Willian Wheeler e disponibilizado em <http://herzberg.ca.sandia.gov/jess/user.html>. Neste trabalho, foi utilizada a versão 6.1 do Jess.

FRIEDMAN-HILL (2003) considera as seguintes possibilidades para o desenvolvimento de aplicações com o Jess:

- Uso apenas de linguagem Jess, sem código em Java.
- Uso apenas de linguagem Jess, mas com acesso a APIs Java.
- Maior parte do código na linguagem Jess, mas com algum código Java na forma de novos comandos Jess escritos em Java.
- Metade do código em linguagem Jess, com uma quantidade substancial de

código Java proporcionado comandos customizados e APIs. O Jess proporciona a função `main()`.

-Maior parte do código em Java, que chama Jess em sua execução.

-Todo o código em Java, o qual manipula Jess inteiramente com as APIs Java.

Visando facilitar a compreensão dos elementos para a construção de um sistema com base em regras, alguns elementos da linguagem Jess são apresentados a seguir.

#### i) Variável

Uma variável Jess pode se referir a um símbolo, um número, um caractere ou uma lista. O nome das variáveis começa com o símbolo “?”. Para atribuir um valor a uma variável, utiliza-se a função *bind*. Por exemplo, *(bind ?a (+ 2 2))* atribui à variável “?a” o valor resultante da soma, ou seja a variável “?a” recebe o valor 4.

#### ii) Fatos

Fatos são parcelas de informação acerca do mundo externo; eles correspondem à menor unidade de informação que pode ser separadamente adicionada ou removida da memória de trabalho de um sistema baseado em regras. A coleção de fatos constitui a *memória de trabalho*. O conteúdo da memória de trabalho é mantido na memória RAM.

Os fatos podem ser *ordenados* ou *não ordenados*. Um fato não ordenado é análogo a uma linha em uma tabela de dados relacional, com campos correspondentes às colunas da tabela, sendo a cada um deles atribuído um nome. Um fato não ordenado possui escaninhos (*slots*) que podem ser especificados em qualquer ordem, daí o nome não-ordenado. Um fato não ordenado pode ter a aparência:

*(pessoa (nome “João da Silva”) (idade 34) (altura 1.70) (peso 90))*

Um fato ordenado é apenas uma lista, sendo que os campos não recebem um nome. Os dados do exemplo anterior são representados como um fato ordenado da forma:

*(pessoa “João da Silva”, 34 1.70 90)*

Os fatos têm um *cabeçalho* (pessoa, nos exemplos acima). O cabeçalho de um fato não ordenado é como o nome de uma tabela na base de dados relacional. A estrutura dos fatos não ordenados é especificada com *deftemplate*. A definição da estrutura de um fato não ordenado contém o cabeçalho e o nome de cada *slot*:

*(deftemplate pessoa “comentário opcional”*

*(slot nome)*

*(slot idade)*

*(slot peso))*

O comando *assert* coloca um fato na memória de trabalho. Para um fato não ordenado, não importa a ordem com que são especificados os escaninhos:

*(assert (pessoa (idade 34) (nome “João da Silva”) (peso 90))*

Os escaninhos não preenchidos receberão um valor *default nil* ou um outro especificado quando da definição do fato com *deftemplate*.

Uma regra pode atuar sobre um fato, modificando-o. Os valores em escaninhos de um fato não ordenado podem ser modificados usando a função *modify*. Uma atualização do escaninho idade pode ser efetuada como *(modify 0 (idade 35))*, sendo 0 um número identificador do fato na memória de trabalho.

### iii) Regras

Uma regra é um tipo de instrução ou comando que se aplica a determinadas situações. A parte “SE” é denominada *lado esquerdo* (“*left-hand size*” ou LHS), predicado ou premissas; e a parte “ENTÃO” é chamada *lado direito* (“*right-hand size*”

ou RHS), ações ou conclusões. O domínio de uma regra é o conjunto de todas as informações com as quais a regra pode possivelmente atuar. As regras podem realizar ações com base no conteúdo da memória de trabalho.

O nome da regra pode ser opcionalmente seguido de um conjunto de caracteres para a descrição do propósito da regra. Na linguagem Jess, o símbolo => (símbolo igual seguido do símbolo maior que) separa o lado esquerdo da regra de sua parte direita e é lido como “ENTÃO”. O lado esquerdo de uma regra consiste de padrões que correspondem a fatos, enquanto o lado direito consiste de chamadas a funções.

#### iv) Motor de regras

Num programa baseado em regras, deve-se escrever as regras individuais e em outro programa, um **motor de regras** (“*rule engine*”) determinará quais regras são aplicáveis e então as executa. A função *run* faz iniciar a execução das regras, uma a cada vez, até que agenda fique vazia. Um motor de regras típico contém:

- um motor de inferência
- uma base de regras
- uma memória de trabalho

A base de regras é composta pelo conjunto das regras. As regras podem realizar ações com base no conteúdo da memória de trabalho. O motor de inferência, por sua vez, consiste de:

- um comparador de padrões
- uma agenda
- um motor de execução

O motor de inferência controla o processo de aplicar regras à memória de trabalho para obter as saídas do sistema. Usualmente um motor de inferência trabalha em ciclos com as etapas:

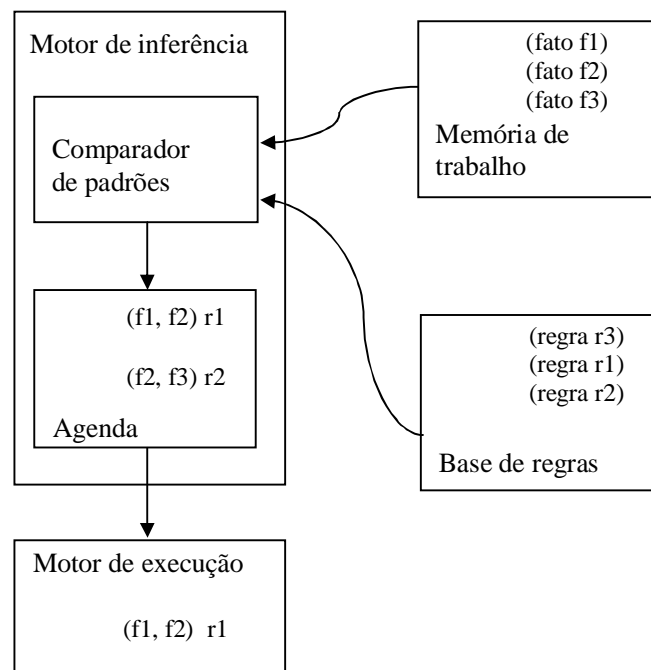
1. Todas as regras são comparadas com a memória de trabalho (usando o comparador de padrões) para decidir qual deve ser ativada durante este ciclo. Esta lista não ordenada de regras ativadas, juntamente com outras regras ativadas em ciclos

prévios, é denominada *conjunto de conflito*.

2. O conjunto de conflito é ordenado para formar a *agenda* – a lista de regras cujos lados direitos serão executados ou disparados. O processo de ordenar a agenda é chamado *resolução de conflito*.

3. Para completar o ciclo, a primeira regra na agenda é disparada, possivelmente modificando a memória de trabalho e, neste caso, o processo inteiro é repetido.

FIGURA 3.2. COMPONENTES DE UM SISTEMA ESPECIALISTA COM BASE EM REGRAS.



Jess tem duas estratégias para a resolução de conflito: *profundidade* (default) e *largura*. Com a estratégia *profundidade*, as regras mais recentemente ativadas serão disparadas primeiro, e com a estratégia *largura* as regras serão disparadas na ordem de ativação – a regra mais recentemente ativada será disparada por último. Profundidade é a estratégia default, e pode ser modificada com o comando *set-strategy*.

A *agenda* é a lista de regras que foram ativadas, mas ainda não foram disparadas. Para algumas aplicações, a agenda conterà apenas uma regra ativada, mas em outras, a agenda conterà múltiplas regras e, neste caso, o gerenciamento da agenda



é importante.

Resumindo, o conjunto de regras ativadas que são elegíveis de serem disparadas é denominado de conjunto de conflito, e o processo de colocar as regras na ordem de disparo é chamado resolução de conflito. A saída do processo de resolução de conflito é a lista de ativações chamada de agenda.

Diz-se que uma regra é disparada quando são executadas as ações da sua parte direita. A função *run* diz para Jess iniciar o disparo de regras da agenda, uma a cada vez, até que a agenda esteja vazia.

As regras podem ser divididas em grupos distintos chamados *módulos*. Os módulos podem servir para fisicamente organizar grande número de dados em grupos lógicos. Os módulos proporcionam um mecanismo de controle: as regras em um módulo disparam somente quando o módulo tem o foco, e apenas um módulo pode ter o foco num determinado instante.

#### v) O algoritmo RETE

A máquina de inferência pode examinar cada regra para verificar quais regras têm seus antecedentes satisfeitos e, então, procurar o conjunto de fatos que determinam se os padrões da regra serão satisfeitos. Se os padrões das regras são satisfeitos, então, a regra pode ser colocada na agenda.

Normalmente, a lista de fatos será modificada durante cada ciclo de execução. Novos fatos podem ser acrescentados à lista de fatos ou fatos antigos podem ser removidos desta lista. Estas mudanças podem fazer com que padrões que não foram satisfeitos anteriormente sejam satisfeitos ou que padrões satisfeitos anteriormente não sejam satisfeitos. Durante cada ciclo, os fatos são acrescentados e removidos, o conjunto de regras que são satisfeitas deve ser mantido e atualizado. As regras permanecem estáticas, e os fatos é que podem mudar.

*Rete* é o termo em latin para rede. O algoritmo Rete é implementado pela construção de uma rede de *nós* interconectados. Cada nó representa um ou mais testes encontrados no LHS de uma regra. Cada nó tem uma ou mais entradas e um número

qualquer de saídas. Fatos que estão sendo adicionados ou removidos da memória de trabalho são processados por esta rede de nós. Os nós de entrada estão no topo da rede, e os nós de saída estão do fundo. Juntos, estes *nós* formam a rede Rete, e esta rede é implementada como a memória de trabalho do Jess (FRIEDMAN-HILL, 2003).

## 4. METODOLOGIA

### 4.1 PRÉ-PROCESSAMENTO DOS DADOS

#### 4.1.1 Geração do MDS e da imagem intensidade

No contexto deste trabalho, a geração do MDS foi feita a partir das coordenadas (E, N, h) dos pontos medidos pelo laser scanner, usando os dados referentes ao primeiro e último pulso e também a intensidade do retorno. Um experimento inicial foi realizado com a projeção dos valores de altitude referentes ao último pulso diretamente sobre uma grade regular, estabelecendo o espaçamento horizontal equivalente à resolução espacial da imagem Quickbird (70cm). Conhecendo as coordenadas UTM dos pontos e, portanto, E mínimo, E máximo, N mínimo e N máximo, foi possível definir o tamanho da grade regular. Em seguida, cada ponto foi lido no arquivo ASCII e o valor de altitude (h) foi projetado na grade regular por meio de um programa desenvolvido no ambiente Matlab. Constatou-se que:

- a) as superfícies de corpos d'água não retornaram o sinal laser, causando regiões correspondentes a “vazios”;
- b) os edifícios altos causaram regiões de oclusão, também causando regiões correspondentes a “vazios” ou regiões onde o sinal laser não chegou devido à oclusão;
- c) as bordas das edificações não ficaram bem definidas, mostrando a necessidade de utilizar o primeiro pulso em conjunto com o último pulso;
- d) em regiões com presença de árvore com copas menos densas, o retorno do último pulso correspondia à superfície situada abaixo da copa;
- e) nas regiões onde houve superposição entre faixas adjacentes, um mesmo objeto tinha variação em altitude, como se tivesse grande variação superficial;

- f) muitas células da grade não receberam nenhum valor, sendo necessária uma forma de preenchimento das mesmas;
- g) o procedimento para a geração de MDS deve evitar estes problemas.

Assim, uma metodologia para a geração da grade regular deve utilizar simultaneamente as medidas do primeiro e último pulso, minimizando os efeitos indicados nos itens c e d acima. A imagem correspondente à intensidade do retorno pode ser gerada simultaneamente com o MDS, minimizando o efeito indicado em f. O efeito indicado nos itens a e b podem ser tratados após a geração da grade. E, finalmente, o efeito indicado em e, pode ser minimizado durante a geração da grade, embora a correção mais adequada seja a do reprocessamento das medidas originais efetuadas com o sistema laser scanner; este reprocessamento das medidas originais não foi considerado no escopo deste trabalho.

#### 4.1.1.1 Metodologia proposta para a geração do MDS

A metodologia para a geração do MDS consiste de quatro etapas:

- 1) projeção dos pontos na grade regular;
- 2) preenchimento dos locais da grade que ficaram vazios a partir dos vizinhos, se existirem, e se os mesmos satisfizerem um critério de homogeneidade;
- 3) aplicação do operador morfológico fechamento para preencher regiões de bordas entre áreas não homogêneas;
- 4) tratamento das regiões sem informação devido à oclusão ou que não retornaram o sinal laser, como superfícies de água.

Os valores de altitude correspondentes ao primeiro e último pulso são projetados sobre uma grade regular, conforme descrito no item 4.1.1. Simultaneamente, é feita a projeção dos valores de intensidade numa segunda grade regular com o mesmo espaçamento. A seguir, para cada posição vazia na grade, efetua-se a verificação de existência ou não de valores na vizinhança; caso existam, se

estes vizinhos atendem a um critério de homogeneidade que considera tanto a diferença de elevação como a diferença no valor de intensidade, a posição da grade é preenchida com o valor correspondente à média dos vizinhos. Uma vez que neste critério são considerados simultaneamente os valores de elevação e de intensidade, se uma posição da grade tiver como vizinhos telhado e árvore, mesmo que eles tenham a mesma altura, a diferença nos valores de intensidade não permitirá o seu preenchimento. Assim, as regiões que correspondem às bordas entre duas regiões homogêneas, como telhados e copas de árvores, não serão modificadas.

O operador *fechamento* da morfologia matemática consiste na aplicação seqüencial dos operadores elementares *dilatação* e *erosão*. Quando o elemento estruturante consiste de uma máscara quadrada contendo em todas as posições o valor 1, a aplicação do operador dilatação pelo elemento estruturante  $S$  à imagem  $A$  consiste das operações:

a) enquanto o elemento estruturante couber sobre a imagem, deslocar  $S$  posicionando, para cada linha de  $A$ , o centro do elemento estruturante em cada coluna de  $A$ ;

b) em cada posição de  $S$  sobre  $A$ , tomar o maior valor de pixel em  $A$  na região ocupada pelo elemento estruturante.

No caso da erosão, no item b é considerado o menor valor de pixel em  $A$ . Na imagem resultante da aplicação da dilatação tem-se a eliminação de padrões escuros e, como consequência, o clareamento da imagem. Estes padrões escuros correspondem aos elementos da grade regular que não haviam sido preenchidos, como as regiões de bordas. Com isto, pode ter havido aumento da extensão de telhados. Aplicando em seguida a erosão, tem-se o efeito contrário, com a diminuição das áreas claras (elevadas) e a recuperação da forma das edificações, embora com suavização e perda de pequenos detalhes. Chaminés, caixas d'água, antenas representam variações na estrutura dos telhados, e podem ter suas elevações alteradas na aplicação do operador fechamento; também em áreas residenciais, onde existe proximidade entre casas, árvores e muros pode haver a junção de tais feições quando se utilizam operadores

morfológicos. O efeito de suavização depende da dimensão do elemento estruturante; no processamento realizado neste experimento, o elemento estruturante foi definido com a dimensão 3x3.

A última etapa, referente ao preenchimento das regiões de oclusão, é feita com a especificação de uma janela para cada região a ser corrigida e da busca, dentro desta janela, do menor valor de elevação. Em seguida, este valor é utilizado para substituir os valores 0 (sem informação) dentro da janela.

O modelo digital de superfície normalizado (MDSn) é obtido fazendo-se a diferença entre o MDS e Modelo Digital de Elevação (MDE). O MDE foi gerado com o software ENVI a partir da informação altimétrica disponível na Carta Topográfica do Centro Politécnico, conforme descrito em 3.2.3.

#### 4.1.1.2 Metodologia proposta para a geração da imagem intensidade

Para a geração da imagem intensidade, foram utilizados os itens 1 e 2 do algoritmo descrito em 4.1.1.1. O operador morfológico fechamento foi substituído pelo filtro da mediana com dimensão 3x3. A aplicação do filtro também reduz a grande variação existente nos valores medidos de intensidade.

#### 4.1.2 Pré-processamento da imagem Quickbird

O pré-processamento da imagem Quickbird consistiu das etapas:

- Geração da ortoimagem,
- Correção do efeito residual na ortoimagem devido à visada inclinada.

Todas as rotinas para o processamento geométrico da imagem Quickbird foram desenvolvidas no ambiente Matlab

#### 4.1.2.1 Modelos geométricos para a geração da ortoimagem

Como se pode perceber na Figura 3.1 (página 60), a imagem Quickbird apresenta um efeito de perspectiva causado pela geometria da aquisição da imagem. Este efeito é mais aparente para edificações mais altas, e deve ser corrigido na geração da ortoimagem, ou seja, de uma imagem em projeção ortogonal. A forma da superfície topográfica e a altura das edificações, necessárias para o processo de correção geométrica, podem ser obtidas a partir do MDS.

Modelos geométricos são necessários para estabelecer a relação funcional entre espaços imagem e objeto. Os modelos podem ser físicos ou generalizados (TAO E HU, 2001). Nos modelos físicos, cada parâmetro tem um significado físico e tem relação com a posição e a orientação do sensor com relação a um sistema de coordenadas do espaço-objeto. Nos modelos generalizados, a transformação entre os espaços imagem e objeto é representada como uma função geral como, por exemplo, um polinômio. Em geral, por não precisarem de conhecimento da geometria do sensor, os modelos generalizados podem ser aplicados a diferentes tipos de sensores.

Com a disponibilidade de imagens de alta resolução espacial, o modelo de polinômios racionais está sendo amplamente utilizado para a correção geométrica, com a utilização de coeficientes polinomiais fornecidos juntamente com as imagens. As empresas proprietárias dos sensores de alta resolução espacial fornecem os parâmetros dos polinômios racionais, mas não fornecem os parâmetros relacionados ao modelo físico do sensor. No processamento efetuado pelas empresas proprietárias dos sensores, o modelo físico do sensor é utilizado para gerar uma grade de pontos e esta grade é utilizada para calcular os coeficientes de polinômios racionais. Como não existem relações funcionais entre os parâmetros do modelo físico e aqueles dos polinômios racionais, os parâmetros físicos não podem ser recuperados a partir dos coeficientes dos polinômios (SHI E SHAKER, 2003). Entretanto, os coeficientes fornecidos juntamente com as imagens podem nem sempre corresponder à superfície terrestre verdadeira.

Uma outra possibilidade é a utilização de modelos generalizados dependentes de terreno. Nestes modelos, o processamento geométrico possui dois passos: a) a transformação espacial que especifica matematicamente a relação entre as coordenadas dos pixels na imagem de entrada e a imagem de saída, e b) a interpolação de valores de cinza para construir a imagem de saída. Os parâmetros da transformação geométrica são calculados utilizando-se o método dos mínimos quadrados (MMQ) para um conjunto de pontos conhecidos nos dois espaços, imagem e terreno, denominados de pontos de controle. Para uma avaliação isenta da qualidade dos parâmetros determinados e da transformação espacial utilizada, deve-se dispor de um segundo conjunto de pontos também conhecidos nos dois espaços, denominados pontos de verificação.

Uma vez conhecidos os parâmetros, estes são utilizados para a construção da imagem ortorretificada. A alternativa considerada neste trabalho é a modelagem geométrica com modelos generalizados dependente de terreno utilizando a informação proporcionada pelo MDS. Neste caso, o efeito causado pelo visada do sensor pode ser também corrigido, já que o MDS contém a altura de cada edificação. Neste estudo, são considerados o modelo de polinômios racionais e a transformação projetiva. Estas transformações são descritas a seguir.

a) Modelo de polinômios racionais

Um polinômio racional é essencialmente uma razão entre dois polinômios e permite melhor interpolação com menor erro de aproximação do que quando da utilização de um único polinômio.

A equação geral para os polinômios racionais é:

$$L_n = P_1 / P_2 \quad (4.1)$$

$$C_n = P_3 / P_4$$

onde  $L_n$  e  $C_n$  são, respectivamente, as coordenadas de imagem (linha e coluna)



normalizadas correspondentes a um ponto objeto  $n$  cujas coordenadas normalizadas são  $X_n$ ,  $Y_n$ , e  $Z_n$ . Para o caso de 3º grau, os polinômios são expressos como:

$$\begin{aligned}
 P1 &= (1 \quad Z_n \quad Y_n \quad X_n \quad Z_n*Y_n \dots Y_n^3 \quad X_n^3)^* (a_0 \quad a_1 \dots a_{19})^T \\
 P2 &= (1 \quad Z_n \quad Y_n \quad X_n \quad Z_n*Y_n \dots Y_n^3 \quad X_n^3)^* (1 \quad b_1 \dots b_{19})^T \\
 P3 &= (1 \quad Z_n \quad Y_n \quad X_n \quad Z_n*Y_n \dots Y_n^3 \quad X_n^3)^* (c_0 \quad c_1 \dots c_{19})^T \\
 P4 &= (1 \quad Z_n \quad Y_n \quad X_n \quad Z_n*Y_n \dots Y_n^3 \quad X_n^3)^* (1 \quad d_1 \dots d_{19})^T
 \end{aligned} \tag{4.2}$$

Os termos  $a_i$ ,  $b_i$ ,  $c_i$  e  $d_i$  são os coeficientes a serem determinados.

O grau dos polinômios racionais deve ser adequado ao fenômeno a ser modelado. Segundo TAO e HU (2001), as distorções causadas pela projeção óptica podem ser geralmente representadas por razões de termos de primeira ordem, enquanto efeitos da curvatura da Terra, refração atmosférica e correção das distorções das lentes podem ser aproximados por termos de segunda ordem. Já a presença de distorções, tais como as causadas pela vibração da câmara, requer termos de ordem superior. Com o objetivo de verificar o desempenho na modelagem do efeito da visada inclinada, foram utilizados os polinômios racionais de ordem um, dois e três.

#### b) Transformação projetiva

A transformação projetiva relaciona coordenadas de objetos no espaço tridimensional com a sua representação bidimensional. A relação entre as coordenadas no espaço  $(X, Y, Z)$  e na imagem  $(L, C)$ , pode ser descrita geometricamente na forma matricial, para coordenadas homogêneas, como:

$$\begin{pmatrix} L' \\ C' \\ 0 \\ W \end{pmatrix} = \begin{pmatrix} a_{11} & a_{12} & a_{13} & a_{14} \\ a_{21} & a_{22} & a_{23} & a_{24} \\ a_{31} & a_{32} & a_{33} & a_{34} \\ a_{41} & a_{42} & a_{43} & 1 \end{pmatrix} \begin{pmatrix} X \\ Y \\ Z \\ 1 \end{pmatrix} \tag{4.3}$$

Os termos  $a_{ij}$  são os parâmetros da transformação projetiva, e  $(L', C', 0, w)$  são as coordenadas homogêneas para o ponto de coordenadas de imagem  $(L,C)$ . As

coordenadas de imagem (L,C) são obtidas fazendo-se

$$L = L' / W \quad (4.4)$$

$$C = C' / W$$

ou , de modo equivalente,

$$L = \frac{(a_{11} X + a_{12} Y + a_{13} Z + a_{14})}{(a_{41} X + a_{42} Y + a_{43} Z + 1)} \quad (4.5)$$

$$C = \frac{(a_{21} X + a_{22} Y + a_{23} Z + a_{24})}{(a_{41} X + a_{42} Y + a_{43} Z + 1)}$$

A transformação projetiva é uma transformação geométrica simples, para a qual a determinação dos parâmetros pode ser feita sem a necessidade de grande número de pontos de controle (JI E ZHANG, 2002).

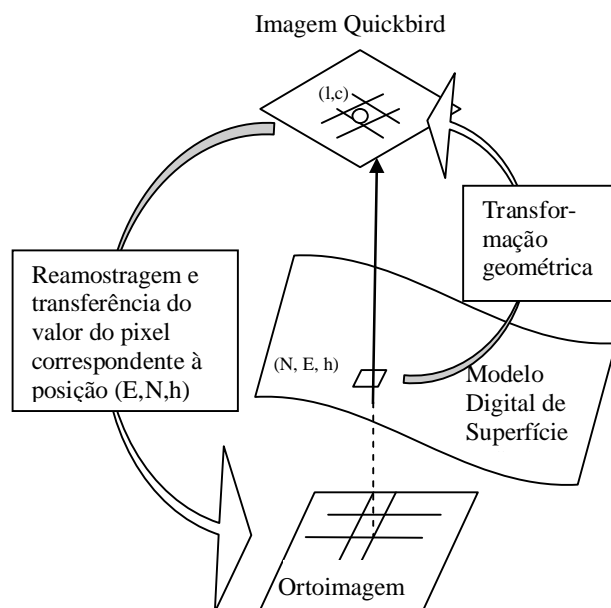
#### 4.1.2.2 Determinação dos parâmetros e geração da Ortoimagem

A resolução dos polinômios racionais tem as soluções iterativa ou direta (TAO e HU, 2001). Neste trabalho, adotou-se a solução direta, sendo consideradas como observações (ou medições) as coordenadas medidas na imagem Quickbird; assim, o método adotado para o ajustamento pelo Método dos Mínimos Quadrados foi o paramétrico. Na solução direta proposta por TAO e HU (2001), a matriz Peso é considerada como uma matriz identidade. A transformação projetiva está na forma linear, e assim, o método de ajustamento é o paramétrico.

Optou-se pelo mapeamento inverso para a geração da ortorectificada, utilizando polinômios racionais de primeira ordem. Os passos do mapeamento inverso estão representados esquematicamente na figura 4.1. No mapeamento inverso, cada banda ortorectificada, é gerada em dois passos:

- a) para cada elemento  $(N,E,h)$  do MDS é calculada a posição correspondente na imagem  $(l,c)$ .
- b) é realizada a reamostragem para definir a partir de valores de pixel na imagem Quickbird, o valor a ser colocado na ortoimagem.

FIGURA 4.1 – ORTORRETIFICAÇÃO COM O MAPEAMENTO INVERSO.



#### 4.2 CÁLCULO DA DECLIVIDADE E DA NORMAL A PARTIR DO MDSN

A declividade (*slope*) é uma medida da variação da superfície e pode auxiliar na separação de elementos como edificações e árvores. As superfícies como telhados têm valor de declividade aproximadamente constante, enquanto que árvores têm valor variável. Para o cálculo da declividade foi utilizada uma máscara 3x3 (ver figura 4.2).

FIGURA 4.2 – MÁSCARA UTILIZADA PARA O CÁLCULO DO GRADIENTE E DA NORMAL.

a	b	c
d	e	f
g	h	i

Fazendo as diferenças, (4.6)

$$\begin{aligned}\Delta x_1 &= c - a; \quad \Delta x_2 = f - d; \quad \Delta x_3 = i - g; \\ \Delta y_1 &= a - g; \quad \Delta y_2 = b - h; \quad \Delta y_3 = c - i;\end{aligned}$$

e:

$$\begin{aligned}\Delta x &= (\Delta x_1 + \Delta x_2 + \Delta x_3) / 3; \\ \Delta y &= (\Delta y_1 + \Delta y_2 + \Delta y_3) / 3;\end{aligned}\tag{4.7}$$

A declividade  $S$  corresponde à intensidade do gradiente:

$$S = ( ((\Delta x)^2 + (\Delta y)^2) / 2 )^{1/2}\tag{4.8}$$

O vetor normal à superfície pode ser calculado com a expressão:

$$N = ( 1 / ( 1 + (\Delta x)^2 + (\Delta y)^2 )^{1/2} ) \cdot [ -\Delta x \quad -\Delta y \quad 1 ]^T\tag{4.9}$$

O vetor normal tem três componentes. Será gerada uma imagem correspondente à terceira componente para representar a variação superficial, sendo que superfícies horizontais tem valor um enquanto superfícies verticais tem valor zero.

### 4.3 CORREÇÃO DO EFEITO RESIDUAL (ÁREAS DE OCLUSÃO)

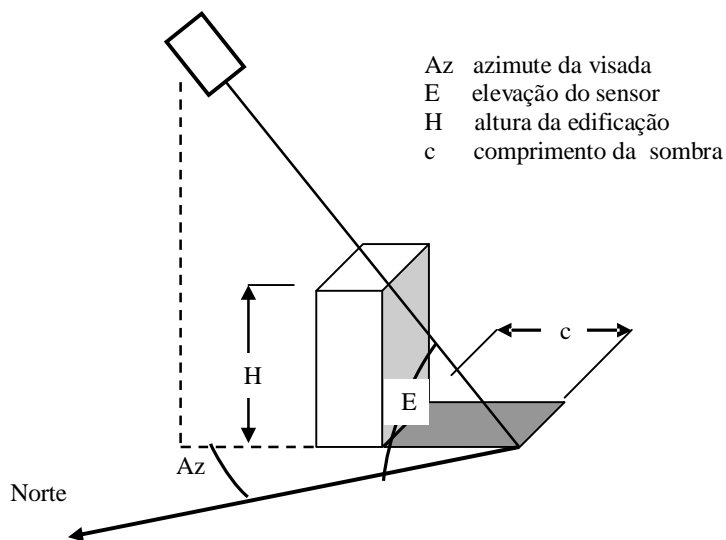
Se forem conhecidos o azimute da visada e o ângulo de elevação do sensor, pode-se utilizar a informação altimétrica do MDSn para simular as áreas de oclusão, ou seja, das áreas da cena que não estão visíveis a partir da posição do sensor, e assim completar o processo de ortorretificação da imagem Quickbird. O ângulo de elevação do sensor pode ser calculado a partir da medida do deslocamento do topo (ainda existente na ortoimagem) e da altura das edificações (no MDS), e o azimute da visada pode ser determinado a partir da direção do deslocamento do topo em relação à sua base. A figura 4.3 mostra os elementos envolvidos na correção.

O ângulo de elevação (E) do sensor pode ser obtido com a expressão:

$$E = \text{arc tg} (H / c), \quad (4.10)$$

sendo  $c$  a diferença de coordenadas entre a base da edificação e a posição da projeção do topo da edificação devido ao efeito de perspectiva na aquisição da imagem. O valor de  $E$  pode ser estimado a partir de medidas de  $H$  e  $c$  efetuadas para várias edificações. O azimute da visada pode ser calculado a partir das coordenadas planimétricas da base das edificações e da posição do correspondente topo devido ao “arraste”, devendo-se efetuar tais medidas em prédios cujas paredes sejam realmente verticais.

FIGURA 4.3 - GEOMETRIA DE IMAGEAMENTO.




Dispondo do azimute e do ângulo de elevação (E) do sensor, pode-se percorrer o MDS segundo a linha correspondente ao azimute da visada e projetar para cada edificação a "sombra" em função da sua altura, numa analogia com o caso da iluminação da cena com uma fonte de luz (figura 4.4). Tal “sombra” corresponde à região de oclusão, e o comprimento  $c$  da “sombra” é dado por:

$$c = H / \operatorname{tg} E$$

(4.11)

Pode-se estabelecer uma altura mínima a partir da qual será feita a projeção da “sombra”. Também se deve verificar a existência de outra edificação na direção da projeção da “sombra” e, se existir, qual é a sua altura para então verificar se esta edificação está ou não visível pelo sensor. Ao longo da linha da sombra, calcula-se a altura  $H'$  para cada posição  $c' < c$ . Se existir uma edificação com altura  $H1$  e  $H1 > H'$ , então  $H1$  não está na “sombra”; caso contrário, a posição atual de  $c'$  corresponde à “sombra”.

FIGURA 4.4 - ELEMENTOS PARA O CÁLCULO DAS ÁREAS DE OCLUSÃO.



Os passos anteriores são efetuados para determinar as áreas de oclusão para todas as feições com altura superior a um valor pré-estabelecido. As árvores podem ter áreas de oclusão em função das variações de altura em suas copas, e podem causar áreas de oclusão na superfície do terreno. Pode-se considerar que as regiões da imagem correspondentes à "sombra" terão valor de pixel igual a zero, pois correspondem a regiões onde a informação sobre o tipo de cobertura do solo não foi

adquirida pelo sensor. Assim, para as áreas de oclusão não existe na ortoimagem a disponibilidade de informações sobre o tipo de cobertura correspondente no terreno.

#### 4.4 CONSTRUÇÃO DA BASE DE REGRAS PARA A CLASSIFICAÇÃO

O especialista humano participa do processo da construção da base de conhecimento nas seguintes etapas (ver figura 4.5):

- Definição de esquema de classificação,
- Seleção de atributos,
- Classificação de pequenas áreas (amostras).

A definição do esquema de classificação consiste na definição da rede semântica utilizada na estruturação das classes. Experimentos em classificação de imagens de alta resolução e de fotografias escanizadas citados no capítulo 2 proporcionam alguns indicativos para o desenvolvimento de um esquema de classificação:

- o desempenho da classificação não será bom para uma classe que tenha parcelas iluminadas e parcelas sombreadas, pois a parcela sombreada poderá apresentar confusão com outras classes (HODGSON et al, 2003);

- devem ser separadas áreas de sombra e não sombra (NAKAJIMA et al, 2002; YU et al, 2002);

- devem ser divididas as feições em acima do terreno e ao nível do terreno (YU et al, 2002);

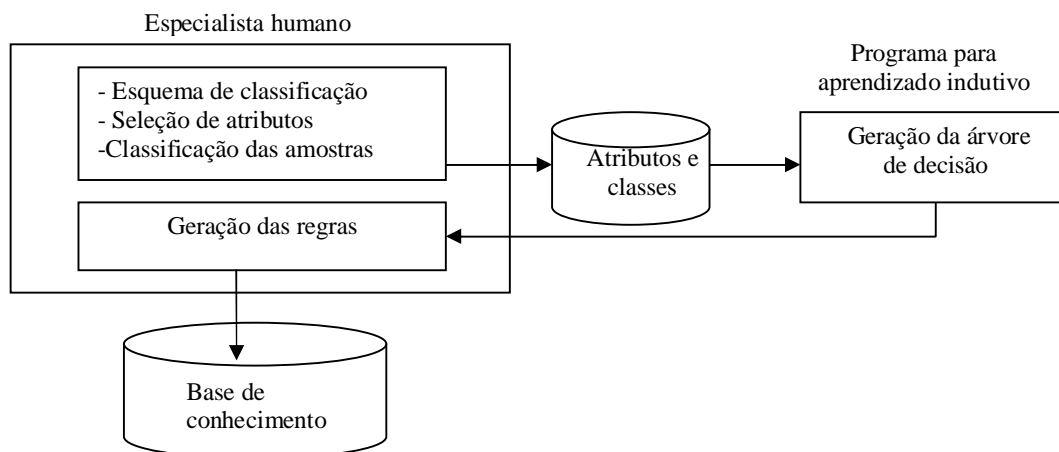
- não devem ser agrupados diferentes tipos de telhado numa única classe (HODGSON et al, 2003), em função das características espectrais (HEROLD et al, 2004) e das características de inclinação superficial e da posição relativa do sensor e do Sol (GERLACH, 2001).

Na abordagem proposta neste trabalho considera-se a classificação conjunta da imagem Quickbird e dos dados derivados das medidas laser scanner num sistema com

base em regras. A ortoimagem Quickbird apresenta áreas de sombras, e também contém áreas sem informação devido à oclusão; por outro lado, na imagem intensidade e no DSMn existe informação relativa às regiões de oclusão na imagem Quickbird, e não existe o problema de sombras causadas pela iluminação solar.

Uma hipótese considerada neste trabalho é a de que os dados de laser scanner podem ser usados para suprir a falta de informações nas regiões de oclusão da imagem Quickbird. Outra hipótese é a de que a classificação das áreas de sombra pode ser melhorada com o uso conjunto de dados espectrais e dados derivados de medidas do laser scanner, sem a necessidade de efetuar as classificações separadamente para as áreas de sombra e não sombra.

FIGURA 4.5 – REPRESENTAÇÃO DO ESQUEMA PARA A CONSTRUÇÃO DA BASE DE CONHECIMENTO.

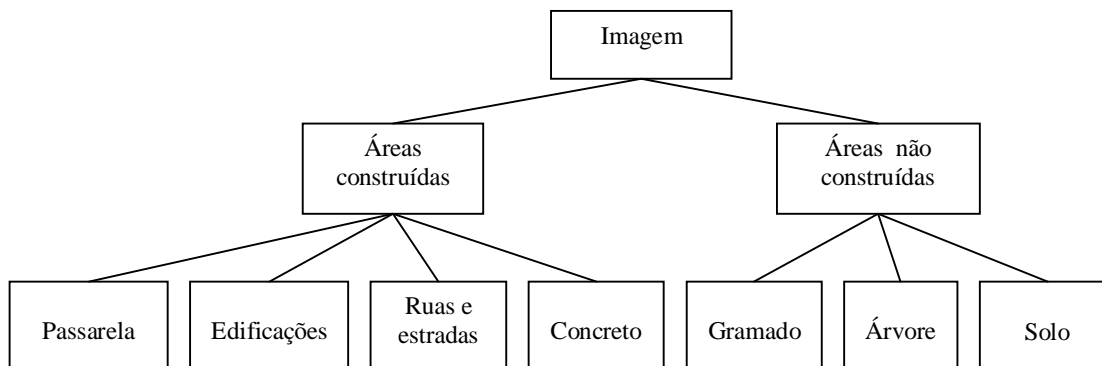


As classes de cobertura do solo foram estruturadas numa rede semântica representada na Figura 4.6, considerando as características espectrais e de elevação. Para cada uma das classes definidas na Figura 4.6, consideram-se as possíveis subclasses em função da característica espectral a partir da imagem Quickbird; a característica espectral pode estar relacionada à cor do material, bem como à inclinação superficial e posição do sensor e do Sol. Cada uma das subclasses será ainda decomposta em iluminada, sombras e oclusão, se existirem estas condições para



a classe em questão.

FIGURA 4.6 - ESQUEMA DA CLASSIFICAÇÃO.



Na abordagem proposta faz-se inicialmente a diferenciação entre subclasses que podem não ser na realidade espectralmente separáveis entre si para, em seguida, após a classificação, agrupar novamente estas subclasses numa única classe, conforme a figura 4.6. Espera-se desta maneira diminuir erros de classificação entre as classes “passarela”, “edificações”, “ruas e estradas”, “concreto”, “gramado”, “árvores” e “solo exposto”.

Nesta abordagem de classificação com base no pixel, cada pixel é representado como um vetor n-dimensional, sendo n correspondente ao número de atributos a serem utilizados. Da ortoimagem Quickbird foram gerados:

- o índice normalizado de diferença de vegetação, a partir das bandas 4 e 3, da forma:

$$\text{NDVI} = (B4 - B3) / (B4 + B3). \quad (4.12)$$

- diferença entre as bandas 3 e 1, da forma

$$\text{Dif31} = B3 - B1 \quad (4.13)$$

- diferença entre as bandas 1 e 3, da forma

$$\text{Dif13} = B1 - B3 \quad (4.14)$$

O índice normalizado de diferença de vegetação pode ter valores de pixel no intervalo entre -1 e 1, sendo que os valores maiores indicam a presença de vegetação fotossinteticamente ativa. A diferença entre as bandas 3 e 1 terá maiores valores para objetos com cor vermelha, como telhados com telhas de cerâmica, e por sua vez, a diferença entre as bandas 1 e 3 terá maiores valores para objetos com cor azul, como telhados.

O *layer* ruas disponível na planta planialtimétrica, pode auxiliar a classificação, uma vez que superfícies de asfalto podem apresentar alterações nas imagens ópticas e na imagem intensidade, causadas pelo envelhecimento do material, ou mesmo pela deposição de material como partículas de solo. Outro atributo utilizado é a intensidade do retorno laser.

Os atributos utilizados apresentam escalas numérica, com exceção do *layer* ruas que tem escala nominal. Será verificado o desempenho do sistema com base em regras na fusão destas diferentes fontes de dados ao efetuar a classificação. O conhecimento do especialista humano utilizado na etapa da definição das amostras de cada classe, ou seja, na classificação de pequenas amostras que serão depois fornecidas para o programa de aprendizado indutivo e servirão como base para o aprendizado e geração da árvore de decisão.

Algoritmos de aprendizado indutivo constituem uma alternativa para a aquisição do conhecimento para formar a base de conhecimento de um sistema especialista, conforme relatado por HUANG e JENSEN (1997). Para o aprendizado indutivo é utilizada uma descrição simbólica para cada classe; esta descrição é feita por meio de propriedades ou atributos. Os atributos correspondem neste caso a valores de pixel. O treinamento visa proporcionar exemplos de conceitos a serem aprendidos. Os exemplos são representados por vetores de atributos das classes, da forma:

[ atributo\_1, atributo\_2, ... , atributo\_n, classe\_i ].

O aprendizado indutivo é feito a partir de amostras, com os valores de atributos, e as respectivas classes. A opção utilizada para o aprendizado é o algoritmo de indução de árvore de decisão J4.8, disponível no pacote Weka. A árvore de decisão pode ser analisada pelo analista humano e, se necessário, pode ser modificada, para então ser convertida em regras que formam a base de conhecimento de um sistema com base em regras.

#### 4.5 CONSTRUÇÃO DA BASE DE CONHECIMENTO

A base de conhecimento consiste da base de regras e da memória de trabalho. Fatos são a menor unidade de informação que pode ser adicionada ou removida da memória de trabalho. Sendo o pixel um vetor n-dimensional, com  $n = 4$ , pode ser representado na linguagem Jess como um fato não ordenado da forma:

```
( deftemplate pixel
  (slot classe (type INTEGER) (default nil))
  (slot b1 (type INTEGER))
  (slot b2 (type INTEGER))
  (slot b3 (type INTEGER))
  (slot b4 (type INTEGER)))
```

Os *slots* correspondem ao valor para a banda, e o tipo está especificado com um valor numérico inteiro. O *slot classe* é especificado como vazio por default, e após a classificação do pixel receberá um valor numérico inteiro relativo à sua classe.

Quando uma regra dispara e se deseja alterar o fato que auxiliou a ativar a regra, pode-se utilizar uma variável que é associada ao fato e então modificar um *slot*. Por exemplo, se um pixel foi classificado como “fundo”, e o *slot classe* está vazio, a variável “?pixelFact” permite modificar o valor do *slot classe* do fato pixel para 30”:

```

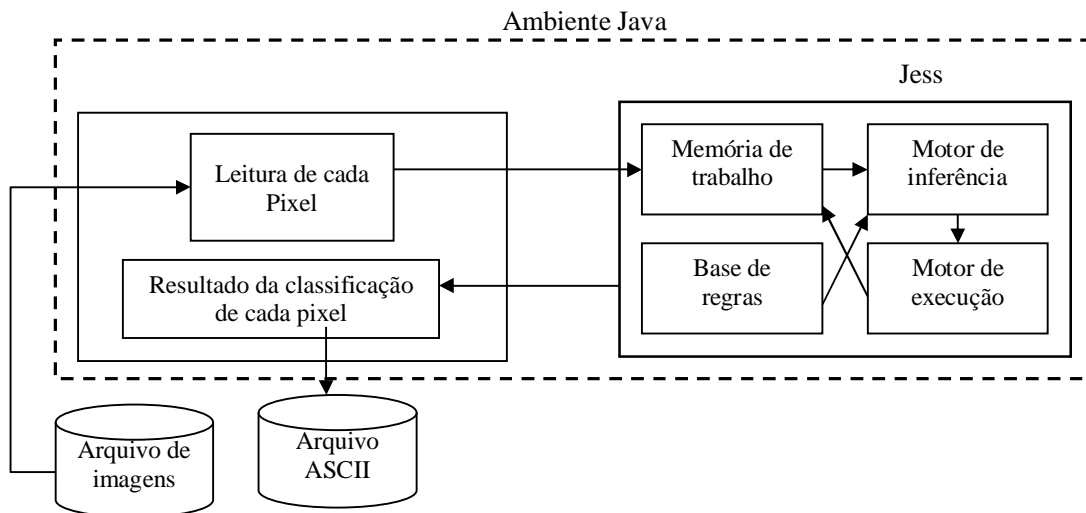
(defrule regra81
  (pixelClasse fundo)
  ?pixelFact <- (pixel (classe nil))
  =>
  (modify ?pixelFact (classe 30)))

```

#### 4.6 CONSTRUÇÃO DO SISTEMA COM BASE EM REGRAS

O programa em Java chamará o Jess em sua execução e carregará a base de regras. A seguir, para cada pixel lido do arquivo o programa acessará o Jess e criará um fato na base de conhecimento e executará em seguida o motor de regras (ver figura 4.7). Algumas regras criarão novos fatos na memória de trabalho. Cada pixel da imagem corresponderá a um novo fato e a base de conhecimento será atualizada para cada novo pixel lido. O resultado da classificação (o número da classe) será retornado para o programa Java, que gravará este valor num arquivo ASCII.

FIGURA 4.7 - FLUXO DE DADOS NO SISTEMA COM BASE EM REGRAS.



## 5. EXPERIMENTOS

### 5.1 GERAÇÃO DO MODELO DIGITAL DE SUPERFÍCIE

O MDS foi gerado para toda a área coberta pelas medidas do sistema laser scanner. O valor de altitude  $h$  foi projetado sobre uma grade regular com espaçamento de 70 cm, como descrito em 4.1.1, gerando 4179 linhas e 3532 colunas. O valor de altitude foi multiplicado por 100 para tornar inteiros os valores a serem projetados na grade. A figura 5.1 mostra os resultados: a) da projeção dos valores originais de altitude na grade, b) do preenchimento considerando o critério de homogeneidade, c) da aplicação do operador fechamento, e d) do preenchimento das regiões de oclusão.


Especialmente para edificações mais altas podem ocorrer várias medidas laser com a mesma coordenada horizontal, porém com diferentes altitudes. Neste caso, quando se deseja representar no MDS o topo de edificações e copas de árvore, bem como a rede de transmissão de energia elétrica, deve-se utilizar o maior valor de altitude; por outro lado, quando se deseja reconstruir a superfície topográfica (Modelo Digital de Elevação) a partir dos dados medidos pelo laser scanner, deve-se optar pelo menor valor.

O critério de homogeneidade utilizado no preenchimento dos locais da grade que ficaram vazios quando da projeção dos pontos levou em conta os dois fatores: (a) variação em altitude entre os pixels vizinhos deve ser menor que 1,5m e (b) variação na intensidade do retorno menor que 15. Estes valores foram determinados experimentalmente. O preenchimento foi feito considerando inicialmente os vizinhos num raio igual a um, e depois os vizinhos num raio igual a dois. A etapa seguinte consistiu na aplicação do operador fechamento da morfologia matemática.

Para o tratamento de cada região de oclusão, definiu-se uma janela e se buscou dentro desta janela o menor valor de elevação; a seguir, as áreas de oclusão que tinham altitude igual a zero receberam este valor de elevação. Em locais onde existe variação da elevação do terreno, o valor calculado considerando a vizinhança não corresponde

ao real; mas se considerou que é preferível ter um valor no MDS, mesmo que aproximado para tais áreas de oclusão, do que não ter o valor de altitude.


FIGURA 5.1 - ETAPAS DA CONSTRUÇÃO DO MDS: a) PROJEÇÃO DOS PONTOS (N,E,h); b) PREENCHIMENTO CONSIDERANDO UM CRITÉRIO DE HOMOGENEIDADE; c) APLICAÇÃO DO OPERADOR MORFOLÓGICO FECHAMENTO; d) PREENCHIMENTO DAS ÁREAS DE OCLUSÃO.



Pode-se observar que o MDS mantém a forma das edificações, e que superfícies horizontais como a de corpos d'água tem elevação constante. As edificações mais altas não estão dentro da área de estudo que corresponde ao Centro Politécnico, mas a

geração do MDS para toda a região coberta pelas medidas efetuadas pelo laser scanner permite uma avaliação do desempenho do método para a geração do MDS para o caso de áreas urbanas mais densas. Na área de estudo, havendo a disponibilidade da informação cartográfica, foi possível superpor o arquivo vetorial ao MDS. A Figura 5.2 mostra um recorte, correspondente ao prédio do Setor de Ciências Biológicas. Comparando o MDS com o mapeamento plani-altimétrico, percebe-se que há um ajuste dos contornos das feições no arquivo vetorial com o MDS, mas não há coincidência exata nas bordas das edificações. A tabela 5.1 mostra a comparação entre coordenadas medidas na carta topográfica e no MDS para 15 pontos.

FIGURA 5.2 - SUPERPOSIÇÃO DO ARQUIVO VETORIAL DA CARTA DO CENTRO POLITÉCNICO SOBRE O MDS.



As medidas efetuadas pelo laser scanner permitem a definição de superfícies, mas não das bordas das feições. Além disso, a densidade de pontos amostrados e o espaçamento da grade regular afetam a definição das bordas das feições. Foram gerados dois modelos digitais de superfície, um com a escolha do maior valor de elevação, descrito anteriormente, e o outro com a escolha do menor valor sempre que vários pontos medidos apresentaram a mesma coordenada horizontal.


A figura 5.3 mostra em vermelho a diferença entre os dois Modelos. No detalhe ampliado na Figura, percebe-se a diferença na borda de uma edificação. O

MDS que recebeu os menores valores de altitude é o mais adequado quando se deseja gerar o Modelo Digital de Elevação a partir das medidas efetuadas pelo laser scanner. Já o MDS que recebeu os maiores valores de altitude contém detalhes como a forma das copas das árvores, postes de iluminação e fios de alta tensão.

TABELA 5.1 - DIFERENÇAS ENTRE COORDENADAS MEDIDAS NA CARTA TOPOGRÁFICA E NO MODELO DIGITAL DE SUPERFÍCIE.

Carta topográfica		Modelo Digital de Superfície		Diferenças		Resíduo (m)
E (m)	N (m)	E' (m)	N' (m)	E-E'	N-N'	
677672,84	7184387,70	677672,97	7184388,15	-0,1300	-0,4500	0,468
677174,71	7184674,05	677174,57	7184675,15	0,1400	-1,1000	1,109
677265,77	7184371,33	677264,87	7184371,35	0,9000	-0,0200	0,900
677847,56	7184053,03	677847,27	7184054,25	0,2900	-1,2200	1,254
677864,73	7183838,33	677865,47	7183838,65	-0,7400	-0,3200	0,806
677804,21	7183661,44	677803,87	7183661,55	0,3400	-0,1100	0,357
677231,13	7183774,14	677231,27	7183774,95	-0,1400	-0,8100	0,822
677295,19	7183899,56	677294,97	7183900,25	0,2200	-0,6900	0,724
677456,12	7183438,94	677456,67	7183439,65	-0,5500	-0,7100	0,898
677983,01	7183789,42	677982,37	7183790,35	0,6400	-0,9300	1,129
677485,54	7184088,46	677486,07	7184088,55	-0,5300	-0,0900	0,538
677115,09	7183969,04	677115,77	7183969,55	-0,6800	-0,5100	0,850
677915,38	7184239,68	677915,17	7184239,75	0,2100	-0,0700	0,221
677281,79	7184724,91	677280,97	7184725,55	0,8200	-0,6400	1,040
676859,12	7184579,72	676860,27	7184580,65	-1,1500	-0,9300	1,479

FIGURA 5.3 - DIFERENÇA ENTRE A UTILIZAÇÃO DOS MAIORES VALORES E MENORES VALORES DE ALTITUDE PARA A GERAÇÃO DO MDS






## 5.2 GERAÇÃO DA IMAGEM INTENSIDADE

A imagem intensidade foi gerada simultaneamente com o MDS. A figura 5.4 mostra os resultados da fase inicial, com a projeção dos valores de intensidade sobre a grade regular, e da última fase, com a imagem final após o preenchimento das regiões de oclusão. Na figura 5.4a pode-se perceber a existência de maior densidade de pontos nas regiões de superposição entre duas faixas de vôo. Na figura 5.4b pode-se perceber uma variação nos valores de intensidade no estacionamento (círculo vermelho) e a diferença no valor de intensidade para dois telhados com o mesmo material superficial, possivelmente devido à inclinação superficial e o ângulo de incidência do feixe laser.

A imagem intensidade tem resolução radiométrica de 8 bits, correspondendo a valores de pixel no intervalo 0 a 255. Pode-se perceber facilmente a diferença entre asfalto e vegetação, mas a diferença entre outras classes de cobertura como árvores e asfalto não é satisfatória apenas com os valores dos pixels.

FIGURA 5.4 - RESULTADOS GERADOS NOS PASSOS INICIAL E FINAL DA CONSTRUÇÃO DA IMAGEM INTENSIDADE.



## 5.3 ORTORRETIFICAÇÃO DA IMAGEM QUICKBIRD

### 5.3.1 Modelagem geométrica

Para a determinação dos parâmetros das transformações descritas no item 4.1.2.1 foram medidas coordenadas de pontos situados em topo e base de edificações. Após a depuração para a eliminação de erros introduzidos no processo de medição, os pontos foram separados em dois conjuntos, o primeiro contendo 42 pontos a serem utilizados na determinação dos parâmetros, e o segundo conjunto contendo 21 pontos de verificação. O número de parâmetros para cada transformação está apresentado na tabela 5.2.

Os parâmetros das transformações foram determinados para o conjunto de pontos de controle. Estes parâmetros foram usados para calcular as coordenadas de imagem para os dois conjuntos de pontos, de controle e de verificação. As diferenças (resíduos) entre as coordenadas medidas e calculadas para os dois conjuntos de pontos são apresentadas na tabela 5.2.

Analisando os resultados para os dois conjuntos de pontos, de controle e de verificação, pode-se constatar que aumentando o grau do polinômio houve diminuição dos resíduos para os pontos de controle, mas um aumento dos resíduos para os pontos de verificação. O resíduo máximo encontrado para pontos de verificação também aumentou conforme o grau do polinômio. Estes resultados indicam que está havendo uma adaptação melhor para o conjunto de pontos de controle, sendo que este comportamento não se aplica para os pontos que não participam deste conjunto.

O polinômio de primeiro grau apresentou maior proximidade para os valores de média e de desvio-padrão para os conjuntos de pontos de controle e de verificação. Já o polinômio de terceiro grau apresentou menores valores de média e desvio-padrão para o conjunto de pontos de controle, mas valores mais elevados de média e desvio-padrão para os pontos de verificação. Observando a variação de valores para os pontos de controle e de verificação, o polinômio de primeiro grau apresentou o melhor desempenho, sendo que o maior resíduo para os pontos de verificação foi de 1,30m. A

transformação projetiva teve um erro máximo de 1,79m para os pontos de verificação, com valor médio de resíduos (0,73m) para os pontos de verificação bastante próximo ao da utilização do polinômio racional de primeiro grau (0,62m).

TABELA 5.2 - RESÍDUOS PARA OS PONTOS DE CONTROLE E DE VERIFICAÇÃO.

	Transf. Projetiva	Pol. 1º grau	Pol. 2º grau	Pol. 3º grau
Número de Parâmetros	15	14	38	74
Resíduos para pontos de controle (em metros)				
Média	0,89	0,55	0,47	0,09
Mínimo	0,14	0,05	0,06	0,00
Máximo	2,52	1,24	1,14	0,29
Desvio-padrão	0,50	0,30	0,26	0,07
Resíduos para pontos de verificação (em metros)				
Média	0,73	0,62	0,75	1,90
Mínimo	0,30	0,16	0,19	0,07
Máximo	1,79	1,30	2,93	11,82
Desvio-padrão	0,73	0,36	0,61	2,94

A figura 5.5 mostra a distribuição dos pontos de controle e verificação, e a figura 5.6 mostra os resíduos para o conjunto de pontos de verificação para a utilização do polinômio racional de primeiro grau.

FIGURA 5.5 - DISTRIBUIÇÃO DOS PONTOS DE CONTROLE E DE VERIFICAÇÃO.





FIGURA 5.6 – RESÍDUOS PARA OS PONTOS DE VERIFICAÇÃO, OBTIDOS COM O POLINÔMIO RACIONAL DE GRAU 1.



No MDS gerado com os maiores valores de elevação estão presentes feições como postes e fios de alta tensão. Mas a elevação destas feições pode fazer com que, na modelagem para a correção do efeito da perspectiva, um mesmo pixel da imagem Quickbird corresponda a uma feição elevada (como poste) e a uma outra feição menos elevada (como a rua). Assim, aplicou-se o filtro da mediana sobre o MDS de modo a eliminar pequenos objetos como postes e linhas de alta tensão e então utilizar este MDS suavizado na geração da ortorectificação. A dimensão do filtro utilizado foi 3x3.

### 5.3.2 Geração da imagem ortorectificada

A ortorectificação foi efetuada para a área em comum entre a imagem Quickbird e o MDS. Na geração de cada banda ortorectificada, foi utilizada a reamostragem com o interpolador bilinear. A figura 5.7 mostra um recorte da banda pancromática original e a figura 5.8 mostra o correspondente recorte após a modelagem geométrica com o polinômio racional.

FIGURA 5. 7 - RECORTE DA BANDA PANCROMÁTICA DA IMAGEM QUICKBIRD.



FIGURA 5. 8- RECORTE DA IMAGEM PANCROMÁTICA APÓS A APLICAÇÃO DA CORREÇÃO GEOMÉTRICA



Na ortoimagem o topo coincide com a base das edificações, porém ainda existe

o deslocamento residual do topo das edificações devido à visada inclinada quando da tomada da imagem. Este deslocamento aparente precisa ser tratado; este passo é descrito na próxima seção.

### 5.3.3 Correção do efeito da visada inclinada

A elevação do sensor foi estimada a partir das medidas efetuadas na ortoimagem e no MDS. Foram efetuadas 6 medidas, e foi adotado o valor médio de  $38^\circ$ . A determinação do azimute da visada também foi efetuada a partir de 6 medidas, e adotado o valor médio de  $21^\circ$ . Ao percorrer as linhas na direção do azimute da visada do sensor, considerou-se que haverá projeção de “sombra” quando a diferença de elevação for superior a dois metros. Tais “sombras” correspondem às regiões de oclusão que não são visíveis a partir da posição do sensor.

A figura 5.9 mostra parte da imagem resultante da projeção da "sombra" para as edificações. A máscara foi aplicada sobre a ortoimagem, e o efeito resultante pode ser percebido na figura 5.10. Os pixels situados nas áreas de oclusão estão com o valor zero, enquanto os pixels nas áreas de sombras devido à posição do Sol têm valor diferente de zero.

FIGURA 5.9 - ÁREAS DE OCLUSÃO NA IMAGEM QUICKBIRD.






FIGURA 5.10 - APLICAÇÃO DA MÁSCARA COM AS REGIÕES DE OCLUSÃO SOBRE A IMAGEM ORTORRETIFICADA.



A figura 5.11 mostra o efeito da aplicação da máscara com as áreas de oclusão sobre a banda pancromática ortorretificada, para a região urbana mais densa, e a figura 5.12 mostra a superposição da informação vetorial sobre a ortoimagem final.

FIGURA 5.11 - APLICAÇÃO DA MÁSCARA COM AS ÁREAS DE OCLUSÃO PARA A REGIÃO DE EDIFICAÇÕES MAIS ALTAS.



FIGURA 5.12 - SUPERPOSIÇÃO DO ARQUIVO VETORIAL SOBRE A IMAGEM ORTORRETIFICADA.



A tabela 5.3 mostra as diferenças entre coordenadas medidas na carta topográfica e na imagem Quickbird ortorretificada, para os mesmos 15 pontos utilizados na comparação entre a carta e o MDS mostrados na tabela 5.2. Tomando as coordenadas da carta topográficas como “corretas”, o maior resíduo foi de 1,47m, sendo 0,881m o valor médio dos resíduos.

TABELA 5.3 - DIFERENÇAS ENTRE COORDENADAS MEDIDAS NA CARTA TOPOGRÁFICA E NA ORTOIMAGEM QUICKBIRD.

Carta topográfica		Ortoimagem		Diferenças		Resíduo (m)
E (m)	N (m)	E' (m)	N' (m)	E-E'	N-N'	
677672,84	7184387,70	677672,97	7184388,15	-0,1300	-0,4500	0,468
677174,71	7184674,05	677175,27	7184675,15	-0,5600	-1,1000	1,234
677265,77	7184371,33	677265,57	7184371,35	0,2000	-0,0200	0,201
677847,56	7184053,03	677847,27	7184054,25	0,2900	-1,2200	1,254
677864,73	7183838,33	677864,77	7183838,65	-0,0400	-0,3200	0,322
677804,21	7183661,44	677804,57	7183662,25	-0,3600	-0,8100	0,886
677231,13	7183774,14	677229,87	7183773,55	1,2600	0,5900	1,391
677295,19	7183899,56	677295,67	7183900,95	-0,4800	-1,3900	1,470
677456,12	7183438,94	677456,67	7183439,65	-0,5500	-0,7100	0,898
677983,01	7183789,42	677983,07	7183790,35	-0,0600	0,4700	0,474
677485,54	7184088,46	677486,07	7184089,25	-0,5300	-0,7900	0,951
677115,09	7183969,04	677115,77	7183970,25	-0,6800	-1,2100	1,388
677915,38	7184239,68	677915,87	7184240,45	-0,4900	-0,7700	0,913
677281,79	7184724,91	677282,37	7184726,25	-0,5800	-1,3400	1,460
676859,12	7184579,72	676859,57	7184580,65	-0,4500	-0,9300	1,033



## 5.4 CONSTRUÇÃO DA BASE DE REGRAS

A figura 5.13 mostra um recorte da ortoimagem Quickbird (bandas 3, 2 e 1 em RGB) e da intensidade do retorno do pulso laser. Pode-se perceber na imagem Quickbird que uma mesma classe pode estar iluminada pelo Sol, estar sombreada, ou mesmo não visível para o sensor (occlusão) quando da aquisição da imagem. A informação referente às regiões de oclusão na imagem Quickbird está disponível na imagem intensidade.

Na imagem Quickbird percebe-se a diferença do material da cobertura de edificações, ao passo que esta diferença não é perceptível na imagem intensidade. Por outro lado, informações de materiais superficiais no nível do solo podem não estar disponíveis da imagem Quickbird, como é o caso das estradas parcialmente cobertas por sombras ou oclusão.

FIGURA 5.13 - RECORTE DA IMAGEM QUICKBIRD (BANDAS 3,2,1) E DA IMAGEM INTENSIDADE.



Assim, as classes “passarela”, “edificações”, “ruas e estradas”, “concreto”, “gramado”, “árvore” e “solo exposto”, definidas no item 4.3 serão subdivididas para contemplar as diferenças espectrais, bem como os efeitos causados pelas sombras e oclusão (ver quadro 5.1).

A classe edificações será subdividida nas subclasses de telhado: “claro”, “azul claro”, “azul”, “cinza” e “cerâmica”. Cada uma destas subclasses, por sua vez, será dividida, quando necessário, em iluminada, sombra e oclusão. No caso do telhado de

cerâmica, a diferença entre “vermelho” e “marrom” pode estar relacionada a fatores como envelhecimento do material, deposição de poeira e sujeira, ou mesmo à diferença de inclinação superficial. Na classe ruas e estradas, além das subclasses iluminado, sombra e oclusão, foi considerada outra subclasse denominada de “asfalto viaduto”, que tem como diferencial a elevação.

QUADRO 5.1 – NÍVEIS DE CLASSIFICAÇÃO.

Nível I	Nível II	Nível III	Nível IV
Áreas construídas	Edificações	Telhado claro	Telhado claro iluminado
			Telhado claro sombra
			Telhado claro oclusão
		Telhado azul	Telhado azul iluminado
			Telhado azul oclusão
		Telhado azul claro	
		Telhado cinza	Telhado cinza iluminado
	Telhado cinza sombra		
	Telhado cinza oclusão		
	Telhado cerâmica	Telhado avermelhado	
		Telhado marrom	
	Passarela		
	Concreto	Concreto iluminado	
		Concreto sombra	
		Concreto oclusão	
	Ruas e estradas	Asfalto iluminado	
		Asfalto viaduto	
		Asfalto sombra	
		Asfalto oclusão	
Áreas não construídas	Árvores	Árvore 1	
		Árvore 2	
		Árvore sombra	
		Árvore oclusão	
		Árvore sobre asfalto	
	Solo exposto	Solo iluminado	
		Solo sombra	
	Gramado	Gramado iluminado	
		Gramado sombra	
		Gramado oclusão	
Fundo			

A classe árvores foi subdividida em cinco subclasses. Verificou-se que existe diferença no comportamento espectral das árvores, levando à diferenciação entre “árvore 1” e “árvore 2”. As outras subclasses correspondem a “sombra”, “occlusão” e

“árvore sobre asfalto”, sendo que esta última corresponde a copas de árvores situadas acima de ruas e estradas.

As classes “concreto” e “gramado” foram subdividas em iluminado, sombra e oclusão; já a classe “solo exposto” foi subdividida apenas em iluminado e sombra, devido a não ocorrência de oclusão. A classe “passarela” não tem subdivisões. Assim, resultaram 29 classes, com o acréscimo de mais uma classe denominada “fundo” para representar a área externa que não corresponde à região de intersecção entre a imagem Quickbird, a imagem intensidade e o MDSn. Após a classificação, estas 30 classes serão reagrupadas em oito classes, as sete classes correspondentes ao nível II apresentado no quadro 5.1, e a oitava classe que corresponde ao “fundo”.

As amostras correspondentes às 30 classes, para os 13 *atributos* analisados, foram adquiridas com o software Multispec. Com o nome das classes e a posição das amostras disponíveis no arquivo de projeto criado pelo Multispec, foram lidos os valores de pixel por meio de um programa desenvolvido em Matlab, o qual gerou um arquivo ASCII contendo os valores de atributo e a identificação da respectiva classe, no formato para a entrada de dados para a indução de árvore de decisão com o pacote Weka.

Os 13 atributos utilizados foram:

- *banda1*, *banda2*, *banda3*, *banda4*, as bandas multiespectrais do sensor Quickbird,
- *banda5*, a banda pancromática do sensor Quickbird,
- *ndvi*, o índice normalizado de diferença de vegetação gerado com as bandas 4 e 3,
- *db1b3*, a diferença entre as bandas 1 e 3,
- *db3b1*, a diferença entre as bandas 3 e 1,
- *slope*, a declividade calculada a partir do MDSn, para feições com elevação maior que 1,5 m,
- *normal*, a componente z do vetor normal calculado a partir do MDSn, para feições com elevação maior que 1,5 m,
- *intensidade*, a intensidade do retorno laser,
- *mdsn*, o modelo digital de superfície normalizado,

- *ruas*, a imagem gerada a partir do mapa planimétrico, com valores 194 (não rua) e 225 (ruas).

O algoritmo J4.8 fornece a árvore de decisão e uma matriz de erros. Analisando a matriz de erros pode-se detectar possíveis problemas na classificação e também a separabilidade entre as classes. A tabela 5.4 mostra parte de uma matriz de erros, onde pode ser percebida a confusão entre as subclasses da classe asfalto e a confusão entre asfalto e concreto.

TABELA 5.4 - ERROS PARA AS CLASSES “ASFALTO” E “CONCRETO” .

Classe (Total)	Asfalto iluminado	Asfalto viaduto	Asfalto sombra	Asfalto oclusão	Concreto iluminado	Concreto sombra	Concreto oclusão
Asfalto Iluminado (669)	614	0	52	2	0	0	0
Asfalto Viaduto (169)	0	164	0	0	0	0	0
Asfalto Sombra (271)	3	0	251	3	0	14	0
Asfalto Oclusão (245)	2	0	1	218	0	0	20
Concreto Iluminado (344)	7	0	0	0	312	0	0
Concreto Sombra (180)	10	0	0	0	4	146	0
Concreto Oclusão (109)	0	0	0	0	0	0	84

Pode-se observar na tabela 5.4 que das 669 amostras (pixels) da classe asfalto iluminado, 52 são identificadas na árvore de decisão como asfalto com sombra, e 2 como asfalto com oclusão, e 1 como de outra classe não mostrada na tabela. Existe dificuldade em separar subclasses como, por exemplo, asfalto iluminado e asfalto com sombra, uma vez que a sombra pode ter diferentes gradações. Considerando que as subclasses serão reunidas em oito classes (“passarela”, “edificações”, “ruas e estradas”, “concreto”, “gramado”, “árvore”, “solo exposto” e “fundo”), teve-se o cuidado de selecionar novas amostras buscando reduzir os erros entre estas classes, embora possa continuar existindo confusão entre as subclasses.

Após a depuração das amostras, obteve-se a árvore de decisão. O algoritmo de aprendizagem de máquina determina, com base no valor calculado para a entropia, o atributo com maior quantidade de informação e o coloca na raiz da árvore de decisão. Em cada nó da árvore, foi feita a divisão em conjuntos cada vez mais homogêneos. O

atributo colocado na raiz da árvore foi o MDSn, correspondendo à divisão em dois grupos: ao nível da superfície topográfica (valor de MDSn menor ou igual a 0.50m) e acima da superfície topográfica (acima de 0.50 m).

A figura 5.14 mostra uma parte da árvore correspondente ao nível da superfície topográfica. A divisão seguinte para este ramo da árvore será em função do atributo “ruas”. O atributo “ruas” tem apenas dois valores: 194 para “não ruas” e 225 para “ruas”. O próximo nó do ramo correspondente ao nível da superfície faz a separação entre “asfalto” (“ruas” maior que 194) e “não asfalto” (“ruas” igual a 194). Seguindo o ramo “não asfalto”, a próxima divisão será entre “áreas de oclusão” (difb3b1 igual a zero) e “não oclusão” (difb3b1 maior que zero). Nas áreas de oclusão, se o valor de NDVI for menor ou igual a zero, então a classe é “30” (fundo). Para valores de NDVI maiores que zero, se o valor de intensidade for menor ou igual a 68, a classe será “7” (concreto oclusão); se o valor de intensidade for maior que 68, a classe será “12” (gramado oclusão).

Assim, a árvore de decisão pode ser interpretada e escrita na forma de regras de decisão que formarão a base de regras do sistema com base em regras. A decisão na raiz da árvore pode ser expressa na forma de duas regras, tendo a primeira no lado esquerdo o fato “valor de MDSn (b12) menor ou igual a 50” e segunda “valor de MDSn (b12) maior que 36”. Do lado direito, são criados novos fatos: “nível do terreno” (regra 1) ou “acima do terreno” (regra 2).

```
(defrule regra1
  (pixel (b12 ?b12))
  (test (<= ?b12 50))
  =>
  (assert(nivel terreno)))

(defrule regra2
  (pixel (b12 ?b12))
  (test (> ?b12 50))
  =>
  (assert(nivel acimaterreno)))
```

FIGURA 5.14 - PARTE DA ÁRVORE DE DECISÃO GERADA PELO ALGORITMO J4.8.

```

mdsn <= 50
| ruas <= 194
| | difb3b1 <= 0
| | | ndvi <= 0: 30
| | | ndvi > 0
| | | | intensidade <= 68: 7
| | | | intensidade > 68: 12
| | difb3b1 > 0
| | | banda1 <= 100
| | | | difb1b3 <= 99
| | | | | ndvi <= 165: 9
| | | | | ndvi > 165: 10
| | | | difb1b3 > 99
| | | | | intensidade <= 102
| | | | | | banda1 <= 73
| | | | | | | intensidade <= 60: 6
| | | | | | | intensidade > 60: 11
| | | | | | banda1 > 73: 6
| | | | | | intensidade > 102: 9
| | | banda1 > 100
| | | | banda4 <= 469
| | | | | intensidade <= 81: 5
| | | | | intensidade > 81: 8
| | | | banda4 > 469: 8
| ruas > 194
| | banda1 <= 83
| | | banda1 <= 0: 4
| | | banda1 > 0: 3
| | banda1 > 83: 1

```

As regras que tiverem todas as condições especificadas no lado esquerdo (a parte “SE”) satisfeitas serão disparadas. Por exemplo, um pixel será identificado como pertencente à “classe gramado com oclusão” se forem satisfeitas as condições: pertencer à superfície topográfica, não tiver cobertura de asfalto, pertencer a uma área de oclusão, e tiver valores de difb3b1 maior que zero e NDVI maior que 68. A regra correspondente tem a forma:

```

(defrule regra9
  (nivel terreno)
  (cobertura naoasfalto)
  (imagem oclusao)
  (pixel (b6 ?b6) (b11 ?b11) )
  (test ( and (> ?b6 0) (> ?b11 68) ) )

```

=&gt;

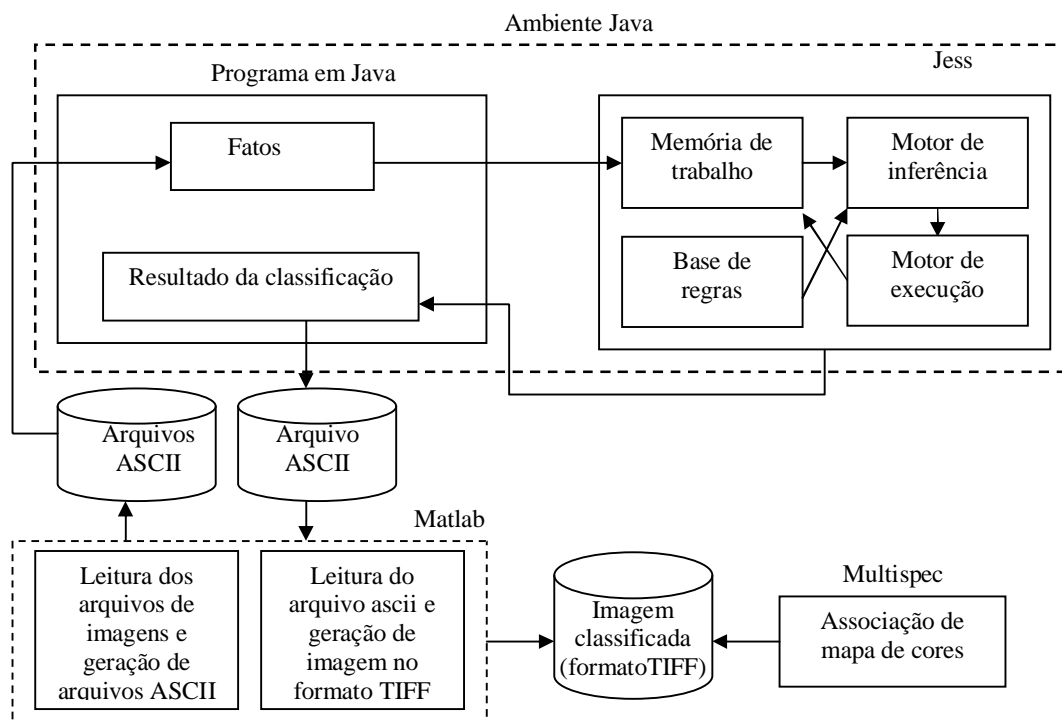
```
(assert(pixelClasse gramadooclusao)))
```

A árvore de decisão foi traduzida em regras que formaram a base de regras. A base de regras foi salva com a extensão .clp, para ser acessada quando da execução do sistema com base em regras.

### 5.5 CLASSIFICAÇÃO COM O SISTEMA COM BASE EM REGRAS

A figura 5.15 mostra o esquema do sistema com base em regras desenvolvido para efetuar a classificação. O programa desenvolvido em Java lê os arquivos correspondentes aos atributos, e chama o Jess, carregando a base de regras. Para cada pixel, são passados os valores para Jess como um novo fato e é iniciada a execução do motor de regras. O resultado da classificação retorna para o programa e é salvo num arquivo ASCII.

FIGURA 5.15 – ESQUEMA DO SISTEMA COM BASE EM REGRAS.



A conversão dos atributos em arquivos ASCII, e a conversão do arquivo ASCII resultante em imagem temática são feitas no ambiente Matlab. A imagem classificada é salva no formato TIFF, e com o Multipec é associado um mapa de cores.

Foram realizadas duas classificações considerando: a) os atributos espectrais e altimétricos (12 atributos), e b) os atributos espectrais, altimétricos e a informação de ruas da carta topográfica (13 atributos).

## 5.6 INTERPRETAÇÃO VISUAL DA IMAGEM QUICKBIRD

A imagem Quickbird ortorretificada foi interpretada considerando as classes definidas para o nível II do quadro 5.1: “edificações”, “passarela”, “ruas e estradas”, “concreto”, “solo exposto”, “árvores” e “gramado”. As classes “ruas e estradas” e “concreto” não são discrimináveis visualmente na imagem Quickbird, e foram consideradas como sendo uma única classe, sendo assim consideradas 6 classes na interpretação visual.

Além do conhecimento do local, fotografias aéreas e o MDSn foram também utilizadas como suporte para a interpretação, possibilitando a análise das regiões de sombra e de oclusão na imagem Quickbird. Algumas feições como, por exemplo, caminhos, puderam ser traçadas com o auxílio das fotografias aéreas. Considerou-se que as árvores apresentam altura maior do que 2m no MDSn, e que a vegetação com altura menor do que 2m pertence à classe “gramado”; este critério foi também utilizado no sistema com base em regras. A figura 5.16 mostra um recorte da composição das bandas 4,3,2 da imagem Quickbird em RGB, e um também recorte do resultado da interpretação visual.


## 5.7 ANÁLISE DO RESULTADO DA CLASSIFICAÇÃO

A classificação foi efetuada com a fusão de informações espectrais, altimétricas e de dados auxiliares (neste caso, a informação de ruas). Os dados utilizados, a



imagem Quickbird e as medidas efetuadas pelo laser scanner, tem diferença temporal maior do que um ano, e não correspondem à mesma estação do ano. Estes fatores podem ter afetado a classificação da vegetação, em especial das árvores. Neste período que decorreu entre a aquisição da imagem Quickbird e a aquisição das medidas com o laser scanner, algumas novas casas foram construídas, e neste caso, como não havia a informação espectral correspondente a telhados, as casas que foram construídas onde havia grama na imagem Quickbird foram classificadas como árvores.

FIGURA 5.16 – COMPOSIÇÃO RGB DAS BANDAS 4,3,2 (ESQUERDA) E A CORRESPONDENTE ANÁLISE VISUAL (DIREITA).




A informação altimétrica permitiu separar “edificações” e “árvores” de outras classes como “gramado”, “solo exposto”, “concreto” e “ruas”. A classificação com o sistema com base em regras utilizando os atributos espectrais e altimétricos teve bom desempenho como se pode perceber na figura 5.17. Aconteceram erros de classificação para “árvores com oclusão”, sendo classificadas como edificações, e “edificações com oclusão”, classificadas como árvores.

Sem a utilização do atributo “ruas” não houve discriminação adequada entre as classes “ruas e estradas” e “concreto”. Com a utilização conjunta da informação adicional da base cartográfica (o atributo “ruas”) as superfícies com asfalto ficaram bem delimitadas, diminuindo a confusão com a classe “concreto”.

A figura 5.18 mostra em marrom o agrupamento da oclusão presente em cada classe. A classificação das áreas de sombra na imagem Quickbird foi possível a partir de atributos espectrais e altimétricos com o sistema com base em regras, embora tenha

havido confusão entre as classes “árvore” e “edificação”. Na figura 5.18 pode-se perceber alguns falsos contornos para edificações e árvores. Tal efeito decorre provavelmente da correção do efeito da oclusão na imagem Quickbird; por ter sido utilizado o MDS filtrado com o filtro da mediana, pode ter havido deslocamento da “sombra” projetada em relação à borda da edificação. Outra possibilidade é o efeito da inclinação da visada do sistema laser, com a ocorrência de reflexão pela parede fazendo com que no MDS a dimensão da edificação seja maior do que o real. No caso das árvores, pode haver uma diferença no tamanho percebido da copa em função da defasagem temporal entre a aquisição da imagem Quickbird e dos dados do laser scanner.

FIGURA 5.17– CLASSIFICAÇÃO COM 12 ATRIBUTOS (ESQUERDA) E 13 ATRIBUTOS (DIREITA).



5.18 – CLASSIFICAÇÃO EFETUADA COM 13 ATRIBUTOS, E POSTERIOR JUNÇÃO DAS CLASSES COM OCLUSÃO.



Quando se faz a superposição do arquivo vetorial sobre a imagem classificada, pode-se perceber que a forma das feições artificiais (“áreas construídas”) classificadas se adapta ao contorno proveniente da restituição fotogramétrica (ver figura 5.19), conforme indicado pelos resíduos mostrados na tabela 5.3. Já para as “áreas não construídas” isto não ocorre. O processo de geração da carta envolve seleção de feições a serem representadas e a generalização cartográfica. Assim, no caso das áreas construídas, percebe-se boa concordância entre o resultado da classificação e a carta; já para a vegetação e solo exposto não se tem boa concordância. Assim, não se pode fazer uma avaliação da qualidade da classificação pela comparação classe a classe com a carta (ver figura 5.20).

A figura 5.21 mostra uma comparação entre a interpretação visual da imagem Quickbird e a imagem classificada com o sistema com base em regras. Para cada classe foram tomadas 30 amostras, cada uma com 4 pixels, aleatoriamente localizadas na imagem classificada, e comparadas com a análise visual. A matriz de erros correspondente à comparação entre a interpretação visual e a classificação com o sistema com base em regras está apresentada na tabela 5.5.



FIGURA 5.19 - SUPERPOSIÇÃO DO ARQUIVO VETORIAL DA CARTA DO CENTRO POLÍTÉCNICO SOBRE A IMAGEM CLASSIFICADA.

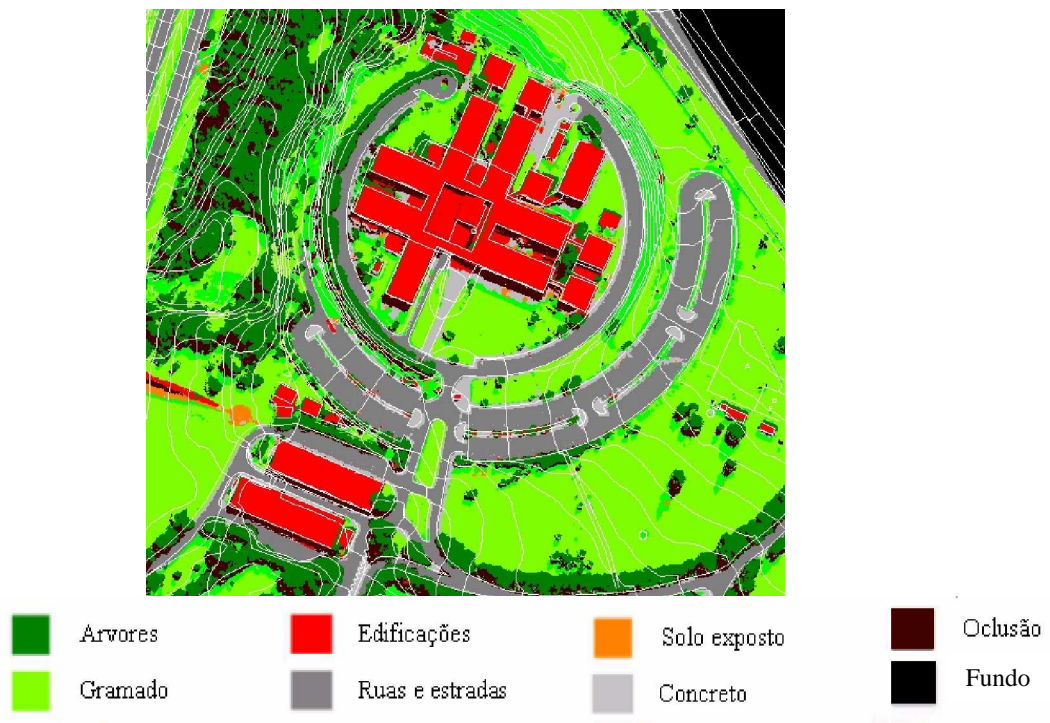


FIGURA 5.20 – COMPARAÇÃO ENTRE A CARTA DO CENTRO POLITÉCNICO E A IMAGEM CLASSIFICADA.



FIGURA 5.21 – COMPARAÇÃO ENTRE A INTERPRETAÇÃO VISUAL (ESQUERDA) E A IMAGEM CLASSIFICADA COM O SISTEMA COM BASE EM REGRAS (DIREITA).




TABELA 5.5 – MATRIZ DE ERROS REFERENTE À COMPARAÇÃO ENTRE A INTERPRETAÇÃO VISUAL E A IMAGEM CLASSIFICADA COM O SISTEMA COM BASE EM REGRAS.

		Interpretação visual					Total ( $\sum x_{+i}$ )	Exatidão do usuário ( $x_{ii} / x_{+i}$ )
		Árvores	Asfalto/concreto	Edificações	Solo exposto	Gramado		
Classificação	Árvores	25	0	4	0	1	30	83,33%
	Asfalto/concreto	0	25	1	0	4	30	83,33%
	Edificações	4	1	24	1	0	30	80,00%
	Solo exposto	0	1	0	22	7	30	73,33%
	Gramado	3	2	0	0	25	30	83,33%
Total ( $\sum x_{i+}$ )		32	29	29	24	37	150	-
Exatidão do produtor ( $x_{ii} / x_{i+}$ )		78,12%	89,28%	82,76%	91,67%	67,57%	-	



Os elementos presentes na matriz de erros, bem como os valores de exatidão do produtor e de exatidão do usuário devem ser analisados levando em consideração a diferença temporal entre as informações espectrais da imagem Quickbird e as informações adquiridas pelo laser scanner. Das amostras tomadas sobre o resultado da classificação com base em regras, verificou-se:

- para a classe “árvores”, houve confusão com “edificações” e “gramado”. Das 30 amostras, 4 correspondem a edificações na interpretação visual; duas destas amostras correspondem a casas não existentes na imagem Quickbird, sendo que o terreno apresentava cobertura de vegetação rasteira quando do imageamento, enquanto que as outras duas amostras correspondem a bordas de edificações.

- para a junção das classes “asfalto” e “concreto”, 4 amostras correspondem a regiões com gramado e cobertas por sombras na imagem Quickbird.

- para a classe “Edificações”, uma das amostras corresponde na imagem Quickbird à rampa da entrada do prédio do Setor de Ciências Biológicas; outras 4 amostras correspondem a regiões de oclusão na imagem Quickbird, mas que na interpretação visual correspondem a árvores. Uma amostra classificada como “edificação” corresponde na imagem Quickbird a solo exposto no estacionamento junto à entrada do Centro Politécnico; entre a aquisição da imagem Quickbird e a aquisição dos dados pelo laser scanner, foram construídas casas nesse local.


- para a classe “solo exposto”, 7 amostras correspondem na imagem Quickbird a gramado, enquanto que 1 amostra corresponde a “concreto/asfalto”. Existe diferença de cobertura do solo entre as datas da aquisição dos dados considerados na análise visual e na classificação, que modificaram as áreas efetivas de “gramado” e “solo exposto”.

- para a classe “gramado”, 3 amostras correspondem na interpretação visual a áreas coberta por árvores. Localizando as 3 amostras no MNSn, constatou-se que são áreas onde o valor de elevação é próximo de zero, indicando que são áreas sem presença de árvores, e que podem ter sido generalizadas como “árvores” na interpretação visual. Outras duas amostras estão situadas sobre calçadas, que foram delimitadas na análise visual com o auxílio de fotografias aéreas, mas não estão bem definidas na imagem Quickbird.

Pode-se verificar que as edificações grandes e/ou isoladas foram bem reconhecidas na classificação. Mas edificações residenciais, menores e próximas entre si, foram discriminadas apenas como um bloco, mas não sendo possível perceber individualmente cada uma das casas. A possibilidade de discriminação das casas individualmente foi em parte afetada pelo procedimento de geração do Modelo Digital de Superfície, com o uso do operador fechamento da morfologia matemática. Por outro lado, conjuntos residenciais compostos por sobrados (ver figura 5.22) com o mesmo material de cobertura, fazendo com que seja um único bloco espectralmente uniforme.

A classe “passarela” apresentou confusão com a classe “edificações”, pela sua característica de elevação e alta reflectância nas bandas visíveis. Também as muretas de concreto do viaduto tiveram confusão com a classe “edificações”. Já o asfalto correspondente às pistas sobre o viaduto foi bem discriminado pela característica de baixa reflectância no visível e no infravermelho, e com o auxílio da informação de “ruas” proveniente da carta topográfica, evitando que houvesse confusão com a classe “edificações”.

FIGURA 5.22 – RESULTADO DA CLASSIFICAÇÃO PARA EDIFICAÇÕES ISOLADAS E PRÓXIMAS ENTRE SI.



## 6. CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES

### 6.1 CONSIDERAÇÕES FINAIS

Os resultados desta pesquisa apontam algumas considerações a respeito da fusão de dados espectrais, altimétricos e dados auxiliares para a classificação da cobertura do terreno, utilizando como ferramenta de classificação de imagens multiespectrais um sistema baseado em regras.

Para a análise conjunta de dados de diferentes fontes, a questão da compatibilização geométrica é essencial, pois garante a boa definição das formas das feições analisadas. As imagens de satélite de alta resolução espacial atualmente disponíveis possuem deformações geométricas decorrentes de fatores como o ângulo de visada, a relativa baixa altura do satélite, a variação da topografia e altura dos objetos acima do terreno. A geometria da observação produz também sombras e áreas de oclusão na imagem, sendo que para estes locais a derivação de informação se torna difícil ou impossível. Este mesmo fenômeno ocorre nos dados obtidos com o laser scanner. Embora os levantamentos com o laser scanner gerem imagens com projeção ortogonal, o processo de aquisição de dados não foge à geometria da projeção central. Todos os feixes usados para medir um trecho do terreno partem de um mesmo ponto. Assim sendo, problemas de oclusão e sombra estão também presentes.

A disponibilidade de dados altimétricos obtidos com laser scanner aerotransportado é cada vez maior, o que também justifica sua inclusão no processo de classificação. A utilização de dados obtidos com laser scanner oferece algumas opções em termos de valores de altitude ou elevação que podem ser utilizadas como variáveis de entrada para o classificador.

A geração da grade altimétrica (MDS) deve estar associada à aplicação pretendida. A utilização do primeiro ou do último pulso proporciona diferentes informações sobre os objetos presentes na superfície do terreno, como casas e árvores.



Quando se deseja informação associada às edificações, deve-se utilizar o primeiro pulso; mas a grade gerada com as tais altitudes pode conter muitos detalhes, como antenas e fios de alta tensão que não estão presentes nas imagens de sensores orbitais de alta resolução espacial. Já a imagem gerada com a intensidade do retorno do feixe laser fornece informação espectral na região do infravermelho próximo, com a possibilidade de diferenciar alguns tipos de cobertura como, por exemplo, gramado e asfalto. Outros tipos de cobertura não são completamente discrimináveis mesmo com a combinação da informação altimétrica e da intensidade do retorno, como é o caso de árvores e telhados, e mais difícil ainda é a separação entre telhados com diferentes materiais e cores.

Os dados espectrais e altimétricos são complementares e seu uso conjunto gera resultados superiores do que quando eles são utilizados de forma isolada. Porém, para garantir que os conjuntos de dados estejam numa base geométrica compatível é indispensável que a imagem de satélite seja ortorretificada. Para isto, o uso da informação altimétrica do laser scanner é de grande valia, pois inclui, além do relevo, informação a respeito dos objetos presentes na superfície que são visíveis na imagem. No que tange à correção geométrica, o modelo de polinômios racionais, com polinômios de primeira ordem, e a transformação projetiva, se mostraram adequados para a ortorretificação de imagens de alta resolução espacial quando se dispõe das informações altimétricas a partir de medidas laser scanner.

A fusão de dados espectrais, dados altimétricos e de dados auxiliares melhora a análise de imagens de alta resolução espacial. Nesta pesquisa optou-se por utilizar uma abordagem baseada no pixel, e os resultados comprovaram que a abordagem com base no pixel baseada numa estrutura de árvore de decisão é adequada. Na classificação usando dados de diversas fontes, o procedimento tradicional de classificação estatística como o método da máxima verossimilhança não é recomendado, pois os dados utilizados, especialmente os dados provenientes de cartas ou de sistemas de informação geográfica não obedecem à suposição de distribuição estatística normal.

A abordagem proposta não é a única solução viável. Existem outras opções,

como, por exemplo, o uso de redes neurais. Mas a abordagem com redes neurais implica na adaptação de pesos entre camadas de neurônios, sendo que tais pesos não possuem um significado fora do contexto da própria rede que foi treinada. Então, quando se deseja explicitar tal conhecimento, pode-se recorrer a outras técnicas do campo da inteligência artificial, como os sistemas com base em regras.

Partindo do conhecimento proporcionado por um especialista humano que fornece exemplos dos conceitos a serem aprendidos, as técnicas de aprendizado indutivo com algoritmos como o C4.5 (e sua implementação no pacote Weka, J4.8) permitem explicitar este conhecimento que pode então ser analisado pelo especialista e, se necessário, corrigido. O conhecimento expresso na forma de árvores de decisão pode ser escrito como regras que formam a base de conhecimento de um sistema com base em regras. Os sistemas com base em regras podem ser criados com o auxílio de arcabouços de sistemas já disponíveis, muitos deles com código-fonte aberto, como o Jess. A utilização de sistemas com base em regras possibilita novas formas de efetivar a análise de dados de sensores remotos, com a possibilidade de integrar informações proporcionadas pelas imagens com informações proporcionadas por outras fontes. Na classificação com um sistema com base em regras pode-se efetuar a classificação apenas de classes de interesse, uma vez base de regras pode conter apenas as regras correspondentes à(s) classe(s) desejada(s); assim, pode-se gerar um mapa temático retratando apenas a classe “edificações”, sendo que todas as demais classes seriam consideradas como “não edificações”.

Nesta implementação, foram utilizadas imagens Quickbird com regiões de oclusão sendo que, para tais regiões os dados de intensidade e altimétricos conseguiram substituir parcialmente a informação faltante. A informação de intensidade e de altimetria não foi adequada para discriminar árvores em regiões de oclusão na imagem Quickbird, o que levou à confusão com edificações na classificação com base em regras; também houve confusão entre as classes solo exposto e vegetação. A utilização da informação de ruas melhorou a definição que não foi possível a partir das outras duas fontes. Alguns erros verificados na classificação

podem estar relacionados à diferença temporal entre as fontes de dados, como o caso de novas casas construídas e de modificações entre gramado e solo exposto, e também à influência da estação do ano, que pode afetar a forma e a densidade do dossel de vegetação. Em relação às áreas construídas, a metodologia proposta foi adequada para edificações isoladas, mas afetou a possibilidade de separar cada casa individualmente quando várias casas estão próximas entre si. Esta deficiência pode ser atribuída à resolução da imagem e da grade altimétrica, bem como à suavização introduzida durante a geração da grade altimétrica.

## 6.2 RECOMENDAÇÕES

- Aplicar o sistema com base em regras informações espectrais e altimétricas adquiridas simultaneamente, como imagens de sensores acoplados ao sistema laser scanner.

- A partir da imagem classificada pode-se continuar a extração de feições como edificações, com procedimentos para regularizar a forma, e minimizar erros existentes no MDS em função da aquisição de pontos pelo laser scanner na forma de varredura que fazem com as bordas não fiquem bem definidas.

- Desenvolver todo o sistema em Java, desde a aquisição de amostras para as classes, passando pelo aprendizado indutivo até a classificação com o sistema com base em regras e a geração da imagem classificada. Java proporciona recursos para o tratamento de imagens, como a API Java 2D, com uma série de funções disponíveis para o caso de imagens coloridas (RGB), ou com três bandas espectrais. O pacote Weka é distribuído com o código-fonte aberto, e consiste de classes Java; o Jess por sua vez, tem o código-fonte aberto, e pode ser integrado completamente com Java.

- A fusão de outras informações, como a das edificações, permitirá a melhor definição da forma, podendo contribuir para inclusive para o refinamento do processo geração do MDS a partir dos pontos medidos pelo laser scanner.

- Considerar para as regras que formam a base de regras do sistema com base em regras diferentes graus de confiabilidade, e que as regras por sua vez podem ser nebulosas (fuzzy).

## REFERÊNCIAS BIBLIOGRÁFICAS

AXELSSON, P. Processing of laser scanner data – algorithms and applications. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, p. 138-147, 1999.

BENZ, Ursula C.; HOFMANN, Peter; WILHAUCK, Gregor; LINGENFELDER, Iris; HEYNEN, Markus. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 58, p. 239-258, 2004.

BIEHL, Larry; LANDGREBE, David. Multispec – a tool for multispectral-hyperspectral image data analysis. **Computers & Geoscience**, v. 28, pp.1153-1159, 2002.

BITTENCOURT, Guilherme. **Inteligência artificial**. Editora da UFSC, Florianópolis, 2001. 362p.

BONHAM-CARTER, Graeme F. **Geographic information systems for geoscientists: modelling with gis**. Pergamon, Kidlington, U.K., 1994. 398p.

CENTENO, Jorge S. Identificação de prédios em imagens de altimetria obtidas usando laser scanner. In: II COLÓQUIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS, 2001, Curitiba. **Anais...** Curitiba: Curso de Pós-Graduação em Ciências Geodésicas, UFPR, 2001. 1 CD-ROM.

CHOI, Jinmu; USERY, E. Lynn. System integration of GIS and a rule-based expert system for urban mapping. **Photogrammetric Engineering and Remote Sensing**, v. 70, n. 2, pp.217-224, 2004.

CHUVIECO, Emilio. **Fundamentos de teledetección espacial**. Ediciones Rialp S.A., Madrid, 1990. 449p.

CORDEIRO, João Paulo da Costa. **Extração de elementos relevantes em texto/páginas da World Wide Web**. Faculdade de Ciências da Universidade do Porto, Cidade do Porto, 2003. Dissertação de mestrado. 174p.

DEAN, Thomas; ALLEN, James; ALOIMONOS, Yiannis. **Artificial intelligence: theory and practice**. Addison-Wesley Publishing Company, Menlo Park, 1995. 563p.

DEITEL, H. M.; DEITEL, P. J. **Java – como programar**. Bookman, Porto Alegre, 2003. 1386p.

DESACHY, Jacky; ROUX, Ludovic; ZAHZAH, El-Hadi. Numeric and symbolic data fusion: a soft computing approach to remote sensing image analysis. **Pattern Recognition Letters**, v.17, pp.1361-1378, 1996.

DOEDERLEIN, Osvaldo Pinali. Programação com regras. **Java Magazine**, Ed. 15, pp.38-48, 2004.

DUTTA, Dushmanta; SERKER, N.H.M. Kamrujjaman. Development of urban building inventory for Bangkok using very high-resolution remote sensing data for disaster risk analysis. In: INTERNATIONAL SYMPOSIUM ON GEOINFORMATICS FOR SPATIAL INFRASTRUCTURE DEVELOPMENT IN EARTH AND ALLIED SCIENCES: GIS-IDEAS 2004. **Anais...**Hanoi, 2004. p. 16-18.

FISCHLER, Martin A.; FIRSCHEIN, Oscar. **Intelligence – the eye, the brain, and the computer**. Addison-Wesley Publishing Company, Reading, 1987.

FREEMAN-HARGIS, James. **Introduction to rule-based systems**. Disponível em: <<http://ai-depot.com>> Acesso em jul. 2005.

FRIEDMAN-HILL, Ernest. **Jess, the expert system shell for the java platform, v6.1RC1**. Disponível em <<http://herzberg.ca.sandia.gov/jess/>> Acesso em 17 jan. 2004.

FRIEDMAN-HILL, Ernest. **Jess in action: rule-based systems in java**. Manning, Greenwich, 2003. 483p.

GERLACH, Frank. How collection geometry affects image tonality. **Imaging Notes**, v. 16, n. 1, p. 6-7, 2001.

GONZALES, R. C. e WOODS, R. E. **Processamento de Imagens Digitais**. Editora Edgard Blücher Ltda, São Paulo, 2000. 509p.

HAY, G.J.; BLASCHKE, T.; MARCEAU, D.J.; BOUCHARD, A. A comparison of three image-object methods for the multiscale analysis of landscape structure. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.57, issues 5-6, pp.327-345, 2003.

HEPNER, George F.; LOGAN, Thomas; RITTER, Niles; BRYANT, Nevin. Artificial network classification using a minimal training set: comparison to conventional supervised classification. **Photogrammetric Engineering and Remote Sensing**. v. 56, n. 4, pp. 469-473, 1990.

HEROLD, Martin; ROBERTS, Dar A.; GARDNER, Margaret E.; DENNISON, Philip. E. Spectrometry for urban area remote sensing – development and analysis of a spectral library from 350 to 2400 nm. **Remote Sensing of Environment**, v. 91, p.302-329, 2004.

HODGSON, Michael; JENSEN, John R.; TULLIS, Jason A.; RIORDAN, Kevin; ARCHER, Clark M. Synergistic use of lidar and color aerial photography for mapping urban parcel imperviousness. **Photogrammetric Engineering and Remote Sensing**. v. 69, n. 9, pp. 973-980, 2003.

HUANG, Xueqiao; JENSEN, John R. A machine-learning approach to automated knowledge-base building for remote sensing image analysis with GIS data. **Photogrammetric Engineering and Remote Sensing**. v. 63, n. 10, pp. 1185-1194, 1997.

HUIPING, H.; BINGFANG, W.; JINLONG, F. Analysis of the relationship of classification accuracy, segmentation scale, image resolution. In: IGARSS, IEEE International Geoscience and Remote Sensing Symposium, 2003, Toulouse. **Anais... IEEE, IGARSS 2003**. 1 CD-ROM.

JI, Z.; ZHANG, J., 2002. 3D visualization of building from lidar and Ikonos image. In: ISPRS COMMISSION II SYMPOSIUM “INTEGRATED SYSTEM FOR SPATIAL DATA PRODUCTION, CUSTODIAN AND DECISION SUPORT”, 2002, Xi’an, China. **Anais... ISPRS**, 2002. p. 213-216.

KIEMA, J. B. K.; BÄHR, H.-P. Fusion of colour infrared imagery and airborne laser scanning data in the automatic classification of urban environments. **Revista Brasileira de Cartografia**, n. 52, 2000. p. 29-36.

LUGER, George F. **Inteligência artificial – estruturas e estratégias para a resolução de problemas complexos**. Bookman, Porto Alegre, 2004. 774p.

MARTINS, Marlo A.R.; FELIX, Daniele; KERSTING, Ana Paula B. Análise do padrão de exatidão cartográfica do sistema laser ALTM 2050. In: CONGRESSO BRASILEIRO DE CADASTRO TÉCNICO MULTIFINALITÁRIO 2004. **Anais...** Florianópolis, UFSC, 2004. 1 CD-ROM.

NAKAJIMA, Takashi; TAO, Guo.; YASUOKA, Yoshifumi. Simulated recovery of information in shadow areas on Ikonos image by combining ALS data. In: Asia Conference on Remote Sensing, 2002. **Anais eletrônicos...** Disponível em <<http://www.gisdevelopment.net/aars/acrs/2002/vhr/index.shtml>> Acesso em ago. 2004.

PAL, Mahesh; MATHER, Paul M. An assessment of the effectiveness of decision tree methods for land cover classification. **Remote Sensing of Environment**, vol. 86 , n. 4, pp. 544-565, 2003.

PAOLA, J.; SCHOWENGERDT, R. A. The effect of neural network structure on a multispectral land-use/land-cover classification. **Photogrammetric Engineering and Remote Sensing**. v. 63, n. 5, pp. 811-821, 1997.

PINHO, Carolina M.D.; RENNÓ, Camilo; KUX, Herman J.H. Avaliação de técnicas de fusão aplicadas à imagem Quickbird. In: Simpósio Brasileiro de Sensoriamento Remoto, XII, Goiânia. **Anais...** INPE, 2005, p. 4225-4232. 1 CD-ROM.

RABEL, George T.; JENSEN, John R.; SCHILL, Steven R.; SCHUCKMAN, Karen. Creation of digital terrain models using an adaptative lidar vegetation point removal process. **Photogrammetric Engineering and Remote Sensing**, v.68, n.12, pp. 1307-1315, 2002.

RABUSKE, Renato Antônio. **Inteligência artificial**. Editora da UFSC, Florianópolis, 1995. 240p.

RICH, Elaine; KNIGHT, Kevin. **Inteligência artificial**. MAKRON Books do Brasil Ltda, São Paulo, 1994. 721p.

RICHARDS, John A.; JIA, Xiuping. **Remote sensing digital image analysis**. Springer, Berlin, 1999. 363p.

SANTOS, Daniel R.; CAVASCIM JUNIOR, Italo; CENTENO, Jorge S.; DALMOLIN, Quintino. Identificação e quantificação de erros planimétricos em edificações representadas em imagens laserscanning. In: MITISHITA, Edson A. (Ed). **Série em Ciências Geodésicas**, v. 3, p. 345-358, 2003.

SCHALKOFF, Robert J. **Digital image processing and computer vision**. John Wiley& Sons, Inc, New York, 1989. 489p.

SCHNEIDER, Mario Jorge; BELLON, Olga R.P.; ARAKI, Hideo. “Experimentos em fusão de imagens de alta resolução”, **Boletim de Ciências Geodésicas**, v.9, n.1, p. 75-88, 2003.

SHI, Wenzhong. e SHAKER, Ahmed. Approximate approaches for geometric corrections of high resolution satellite images. **Photogrammetric Engineering and Remote Sensing**, v.69, n.12, p. 1359-1366, 2003.

SCHIEWE, J. Segmentation of high-resolution remotely sensed data – concepts, applications and problems. In: ISPRS Symposium on Geospatial Theory, Processing and Applications, Ottawa, 2002. **Anais...** ISPRS, 2002.

SHACKELFORD, A.K.; DAVIS, C.H. A *Fuzzy* Classification Approach for High-Resolution Multispectral Data Over Urban Areas. In: IGARSS, IEEE International Geoscience and Remote Sensing Symposium, 2002. **Anais...** IEEE, IGARSS 2002, p. 1621-1623.

ŠIMIĆ, Goran; DEVEDŽIĆ, Vladan. Building an intelligent system using modern Internet technologies. **Expert Systems with Applications**, V. 25, pp.231-245, 2003.

SMITH, S.L.; HOLLAND, D.; LONGLEY, P. **Interpreting interpolation: the pattern of interpolation errors in digital surface models derived from laser scanning data**. Centre for Advanced Spatial Analysis, University College London. <disponível em [http://www.casa.ucl.uk/working\\_papers/paper66.pdf](http://www.casa.ucl.uk/working_papers/paper66.pdf)> Acesso em set. 2004.

SONG, Jeong-Heon; HAN, Soo-Hee; YU, Kiyun; KIM, Yong-Il. Assessing the possibility of land-cover classification using lidar intensity data. In: Photogrammetric Computer Vision, 2002, Graz, Austria. ISPRS, 2002. **Anais eletrônicos...** Disponível em:<<http://www.isprs.org/comission3/proceedings/content2.htm>> Acesso em jan. 2005.

STEINLE, Eberhard; VÖGTLE, Thomas. Effects of different laser scanning modes on the results of building recognition and reconstruction. In: ISPRS Congress, XIX, 2000. **Anais...** ISPRS, 2000, v.33, B3, pp 858-865.

TAO, C. V. e HU, Y. A comprehensive study of the rational function model for photogrammetric processing. **Photogrammetric Engineering & Remote Sensing**, v.67, n.12, p. 1347-1357, 2001.

TAO, G.; YASUOKA, Y. Combining high resolution satellite imagery and airborne laser scanning data for generating bareland dem in urban areas. In: "Visualization and Animation" ISPRS Workshop, Kunming, China, 2002. **Anais...** International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, vol.XXX IV part No. 5/W3.

THOMAS, Nancy; HENDRIX, Chad.; CONGALTON, Russel. G. A comparison of urban mapping methods using high-resolution digital imagery. **Photogrammetric Engineering and Remote Sensing**, v. 69, n. 9, p. 963-972, 2003.

TSATSOULIS, Costas. Expert systems in remote sensing applications. **IEEE Geoscience and Remote Sensing Newsletter**, jun 1993. Disponível em: <<http://www.ewh.ieee.org/soc/grss/newletter/Jun93art.pdf>> Acesso em jan. 2005.

WILKINSON, Graeme G. Recent developments in remote sensing technology and the importance of computer vision analysis techniques. In: KANELLOPOULOS, I.; WILKINSON, Graeme.G.; MOONS, Theo. (Ed.) **Machine vision and advanced image processing in remote sensing**. Springer-Verlag, Berlin, 1999.

WILKINSON, Graeme G. Results and implications of a study of fifteen years of satellite image classification experiments. **IEEE Transactions on Geoscience and Remote Sensing**, vol. 43, n. 3, pp.433-440, 2005.

VAN DE VOORDE, T.; DE GENST, W.; CANTERS, F.; STEPHENNE, N.; WOLFF, E.; BINARD, M. Extraction of land use/land cover-related information from very high resolution data in urban and suburban areas. GOOSENS, Rudi (Ed): **Remote Sensing in transition**. Millpress, Rotterdam, 2004. pp.237-244.

YU, Z. JXIAN, Z.; WANG. G.; LIN, Z. Urban land-use classification using integrated airborne laser scanning and high resolution multi-spectral satellite imagery. In: ISPR CI Symposium, Denver, November 10-15, 2002. ISPRS, 2002. **Anais eletrônicos...** Disponível em:<<http://www.isprs.org/commission1/proceedings/paper/00100.pdf>> Acesso em dez. 2004.

ZHANG, Y. Texture-Integrated Classification of Urban Treed Areas in High-Resolution Color Infrared Imagery. **Photogrammetric Engineering & Remote Sensing**. v.67, n.12, p. 1359-1365, 2001.



ZINGER, S.; NIKOLOVA, M.; ROUX, M.; MAÎTRE, H. 3D resampling for airborne laser data of urban áreas. In: Photogrammetric Computer Vision, 2002, Graz, Austria. ISPRS, 2002. **Anais eletrônicos**...Disponívelem:<<http://www.isprs.org/comission3/proceedings/content2.htm>> Acesso em jan. 2005.

# Livros Grátis

( <http://www.livrosgratis.com.br> )

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)  
[Baixar livros de Literatura de Cordel](#)  
[Baixar livros de Literatura Infantil](#)  
[Baixar livros de Matemática](#)  
[Baixar livros de Medicina](#)  
[Baixar livros de Medicina Veterinária](#)  
[Baixar livros de Meio Ambiente](#)  
[Baixar livros de Meteorologia](#)  
[Baixar Monografias e TCC](#)  
[Baixar livros Multidisciplinar](#)  
[Baixar livros de Música](#)  
[Baixar livros de Psicologia](#)  
[Baixar livros de Química](#)  
[Baixar livros de Saúde Coletiva](#)  
[Baixar livros de Serviço Social](#)  
[Baixar livros de Sociologia](#)  
[Baixar livros de Teologia](#)  
[Baixar livros de Trabalho](#)  
[Baixar livros de Turismo](#)