

LEONARDO CAMPOS DE ASSIS

**USO DE INFORMAÇÕES CONTEXTUAIS NO PROCESSO DE
CLASSIFICAÇÃO DE IMAGENS DO SENSORIAMENTO REMOTO**

Dissertação apresentada
à Universidade Federal de
Viçosa, como parte das
exigências do Programa de Pós-
Graduação em Engenharia
Civil, para obtenção do título de
Magister Scientiae.

VIÇOSA
MINAS GERAIS-BRASIL
2008

**Ficha catalográfica preparada pela Seção de Catalogação e
Classificação da Biblioteca Central da UFV**

T

A848u
2008 Assis, Leonardo Campos de, 1980-
Uso de informações contextuais no processo de
classificação de imagens do sensoriamento remoto / Leonardo
Campos de Assis. – Viçosa, MG, 2008.
xvi, 121f. : il. (algumas col.) + 1 DVD ; 29cm.

Inclui apêndices.

Orientador: Carlos Antônio Oliveira Vieira.

Dissertação (mestrado) - Universidade Federal de Viçosa.

Referências bibliográficas: f. 100-105.

1. Sensoriamento remoto. 2. Processamento de
imagens - Técnicas digitais. 3. Teoria bayesiana de decisão
estatística. I. Universidade Federal de Viçosa. II. Título.

CDD 22.ed. 621.3678

LEONARDO CAMPOS DE ASSIS

**USO DE INFORMAÇÕES CONTEXTUAIS NO PROCESSO DE
CLASSIFICAÇÃO DE IMAGENS DO SENSORIAMENTO REMOTO**

Dissertação apresentada
à Universidade Federal de
Viçosa, como parte das
exigências do Programa de Pós-
Graduação em Engenharia
Civil, para obtenção do título de
Magister Scientiae.


APROVADA: 8 de julho de 2008


Prof. José Marinaldo Gleriani


Prof. Fabyano Fonseca e Silva


Prof. Leonardo Castro de Oliveira


Prof. José Carlos Penna de
Vasconcellos


Prof. Carlos Antônio Oliveira Vieira
(Orientador)

EPÍGRAFE

“Ânimo! Não é cedendo ao ócio nem refestelando-se sobre plumas que se obtém êxito. Aquele que à inatividade se entregar deixará de si sobre a terra memória igual ao traço que o fumo risca no ar e a espuma traça na onda. Vence a fadiga e o torpor, recobra o ânimo, que das vitórias sobre os perigos, a primeira é a da vontade sobre o corpo.”

Dante Alighieri.

*Aos meus pais, Jovem e Carmen e,
à minha querida esposa Carminha,
dedico.*

AGRADECIMENTOS

À CAPES pelo incentivo financeiro em forma de bolsa de estudos, que me possibilitou dedicação exclusiva à pesquisa.

Ao Prof. Carlos Vieira, pela orientação, apoio, incentivo, paciência e dedicação. Em todo o momento ajudando na solução de problemas e contratempos que surgiram.

Aos profissionais da Secretaria Municipal Adjunta de Meio Ambiente de Belo Horizonte, em especial Helen, Agnus e Rodrigo, pela colaboração, pronto apoio e auxílio sempre que solicitados.

Aos meus pais, Jovem e Carmen, por absolutamente tudo que fazem por mim, pelo amparo e motivação em todas as fases da minha vida e, principalmente, por suas orações. E ao caro irmão Rodrigo, sempre amigo e companheiro, pelo constante incentivo e amizade.

Aos meus sogros, Elizabeth e Euphranor, pelo carinho, constante incentivo e apoio emocional em todos os momentos e financeiro nos momentos mais difíceis.

Aos meus colegas de batalha, Rafael Andrade, Giuliano Marotta e Rômulo Gonçalves, pelo apoio, incentivo e paciência, em vários momentos de dificuldade, me ajudando sempre a superar as dificuldades encontradas.

À cara professora Lúcia Calijuri, pela amizade de longa data, por ter me mostrado o caminho, auxiliado e incentivado desde que nos conhecemos, incondicionalmente.

Ao professor Dalto Rodrigues, por seu exemplo de dedicação ao trabalho e auxílio, sempre com boa vontade. Aos professores Simões, Petternelli, Fabyano, Elpidio, Vicente, Joel e Nerilson pelos conselhos dados. Em especial ao professor Nerilson Terra, pela contribuição com conversas, esclarecimentos e empréstimo de material bibliográfico pessoal, fundamentais e esclarecedores à realização do trabalho.

À Marcelo Corrêa, pela valiosa amizade e idéias, sempre procurando ajudar. Também aos amigos Edgard Neto, André Fernandes, Luís César Drumond, Rouverson Silva e Márcio Nogueira, pela amizade e auxílio no caminho percorrido.

Principalmente à minha cara esposa Carminha. Meu Muito Obrigado! Mesmo sabendo ser pouco para descrever o tamanho da gratidão que sinto, por tamanho apoio, incentivo, carinho, dedicação, amor e companheirismo que me dedica.

BIOGRAFIA

LEONARDO CAMPOS DE ASSIS, filho de Jovem Campos de Assis e Carmen Shirley Silva de Assis, nasceu em 9 de janeiro de 1980, na cidade de Uberaba, Minas Gerais.

Em 1995 iniciou o curso de Técnico em Química de ensino médio/profissionalizante na Escola de Química e Agrimensura de Uberaba – Instituto de Escolas Técnicas e Industriais de Uberaba (IETIU), Uberaba – MG, concluindo o curso em 1998. No ano de 2000 ingressou no Curso de Bacharelado em Sistemas de Informação na Universidade de Uberaba (UNIUBE), Uberaba – MG, concluindo a graduação em 2005.

Em maio de 2006 iniciou os estudos de pós-graduação pelo Programa de Pós-Graduação em Engenharia Civil – Área de Concentração em Informações Espaciais, Linha de Pesquisa em Geoprocessamento com ênfase em Sensoriamento Remoto, nível mestrado, na Universidade Federal de Viçosa (UFV). Submeteu-se à defesa da dissertação em 8 de julho de 2008.

SUMÁRIO

| | |
|--|-----|
| LISTA DE SIGLAS E ABREVIACÕES..... | vii |
| LISTA DE FIGURAS | ix |
| LISTA DE TABELAS | xi |
| RESUMO | xii |
| ABSTRACT | xiv |
| 1. INTRODUÇÃO..... | 1 |
| 1.1 Caracterização do problema..... | 2 |
| 1.2 Motivação e justificativas..... | 3 |
| 1.3 Hipótese de pesquisa..... | 4 |
| 1.4 Objetivo..... | 5 |
| 1.5 Organização..... | 6 |
| 2. REVISÃO DA LITERATURA E FUNDAMENTAÇÃO TEÓRICA..... | 7 |
| 2.1 Características das imagens de satélite..... | 7 |
| 2.2 Correção geométrica e ortorretificação..... | 9 |
| 2.3 Correção ou atenuação atmosférica..... | 12 |
| 2.4 Classificação de imagens..... | 15 |
| 2.5 O contexto e o conhecimento especialista..... | 19 |
| 2.6 Informações contextuais..... | 23 |
| 2.7 O Paradigma Bayesiano..... | 25 |
| 2.7.1 Um pouco sobre Thomas Bayes..... | 26 |
| 2.7.2 O raciocínio Bayesiano..... | 28 |
| 2.7.3 Aplicações do paradigma Bayesiano ao sensoriamento remoto..... | 31 |
| 2.8 O Teorema de Bayes..... | 33 |
| 2.9 Determinação do modelo probabilístico..... | 34 |
| 3. MATERIAL E MÉTODOS | 39 |
| 3.1 Introdução..... | 39 |
| 3.2 Área de estudos e características da base de dados..... | 39 |
| 3.3 Recursos computacionais e de software..... | 47 |

| | | |
|-------|--|-----|
| 3.4 | Preparação dos dados..... | 47 |
| 3.4.1 | Edição vetorial..... | 49 |
| 3.4.2 | Geração do Modelo Digital de Elevação (MDE)..... | 50 |
| 3.4.3 | Ortorretificação..... | 52 |
| 3.4.4 | Correção atmosférica..... | 55 |
| 3.4.5 | Definição e refinamento das informações contextuais..... | 59 |
| 3.4.6 | Amostragem e avaliação da classificação..... | 66 |
| 3.5 | Modelagem direta do contexto..... | 67 |
| 3.6 | Modelagem indireta do contexto..... | 72 |
| 4. | RESULTADOS E DISCUSSÃO..... | 83 |
| 4.1 | Modelagem direta..... | 83 |
| 4.2 | Modelagem indireta..... | 85 |
| 4.2.1 | Determinação de imagens fundamentais em valores de probabilidade..... | 86 |
| 4.2.2 | Validação do método e classificação da imagem..... | 93 |
| 4.2.3 | Quantificação de área das classes informacionais..... | 95 |
| 4.2.4 | Pós-classificação..... | 97 |
| 5. | CONCLUSÃO..... | 98 |
| 6. | REFERÊNCIAS..... | 100 |
| | APÊNDICE A..... | 106 |
| A 1. | Parâmetros de 122 pontos de controle utilizados na imagem “A”..... | 106 |
| A 2. | Parâmetros de 96 pontos de controle utilizados na imagem “B”..... | 108 |
| A 3. | Parâmetros de 78 pontos de controle utilizados no agrupamento de imagens “CDE”..... | 110 |
| | APÊNDICE B..... | 113 |
| B1. | Exemplo de um arquivo infiles.txt, com os nomes dos arquivos de entrada no programa 6S. Informações entre parênteses são consideradas comentários pelo programa..... | 113 |
| B2. | Exemplo de um arquivo (*.txt) com os parâmetros de condições atmosféricas de entrada no programa 6S. As informações entre parênteses são comentários..... | 113 |
| B3. | Exemplo de um arquivo (*.res), sua estrutura geral impressa em todas as saídas do programa 6S. Tela de apresentação, seguida por nomes dos arquivos utilizados como entrada bem como os respectivos nomes de saída, parâmetros de saída calculados, mensagem de advertência (quando for o caso)..... | 114 |
| | APÊNDICE C..... | 117 |

| | |
|--|-----|
| C 1. Matriz de erros obtida pela comparação das categorias da imagem classificada com as categorias da imagem de referência. Foi empregado o processo de CMV com probabilidades uniformes <i>a priori</i> para as classes, através do método Classificação Tradicional. | 117 |
| C 2. Matriz de erros obtida pela avaliação do método de Classificação Contextual utilizando imagens com valores fundamentados em probabilidade como probabilidades iniciais para as classes informacionais de vegetação no processo de CMV. | 118 |
| APÊNDICE D | 119 |
| D 1. Carta-imagem obtida pelo método de Classificação Contextual, submetida a operação de filtragem com janela-móvel de dimensões 3x3 pixels. | 119 |
| D 2. Carta-imagem obtida pelo método de Classificação Contextual, submetida a operação de filtragem com janela-móvel de dimensões 5x5 pixels. | 120 |
| D 3. Carta-imagem obtida pelo método de Classificação Contextual, submetida a operação de filtragem com janela-móvel de dimensões 7x7 pixels. | 121 |

LISTA DE SIGLAS E ABREVIACOES

| | |
|-------------|--|
| 6S | <i>Second Simulation of the Satellite Signal in the Solar Spectrum</i> |
| AR | <i>Apparent Reflectance</i> |
| AVHRR..... | <i>Advanced Very High Resolution Radiometer</i> |
| BRME | <i>Bayes Rule for Minimum Error</i> |
| CC | Campo Cerrado |
| CCD | <i>Charge Coupled Device</i> |
| CE..... | Cerrado |
| CMV..... | Classificao pela Mxima Verossimilhana |
| COST | <i>Cosine Approximation Model</i> |
| CP..... | Campo plantado |
| DOS..... | <i>Dark Object Subtraction</i> |
| ESRI | <i>Environmental System Research Institute</i> |
| EV | Eqidistncia Vertical |
| FN..... | Floresta Nativa |
| FP | Floresta Plantada |
| IBGE | Instituto Brasileiro de Geografia e Estatística |
| INMET | Instituto Nacional de Meteorologia |
| IQVU..... | Índice de Qualidade de Vida Urbana |
| MDA | Modelo Digital de Azimute da face de maior declividade |
| MDD | Modelo Digital de Declividades |
| MDE..... | Modelo Digital de Elevao |
| MDEHC | Modelo Digital de Elevao Hidrolgicamente Consistente |
| MDL..... | Modelo Digital de faces Leste |
| MDN | Modelo Digital de faces Norte |
| MVC..... | Matriz de Varincia-Covarincia |

| | |
|--------------|--|
| NCAVEO | <i>Network for Calibration and Validation of Earth Observation</i> |
| NDVI..... | <i>Normalized Difference Vegetation Index</i> |
| NIR..... | <i>Near Infra-Red</i> |
| NOAA | <i>National Oceanic and Atmospheric Administration</i> |
| NVD | Número de Variáveis Discriminantes |
| PBH..... | Prefeitura de Belo Horizonte |
| PC | Ponto de Controle |
| PI | Plano de Informação |
| REM | Radiação Eletromagnética |
| RLB | Regressão Logística Binomial |
| RMS | <i>Root Mean Square</i> |
| ROC | <i>Relative Operating Characteristic</i> |
| RPC | <i>Rational Polynomial Coefficient</i> |
| RPF..... | <i>Rational Polynomial Function</i> |
| SAD..... | <i>South American Datum</i> |
| SAR..... | <i>Synthetic Aperture Radar</i> |
| SGB..... | Sistema Geodésico Brasileiro |
| SIG | Sistema de Informações Geográficas |
| SIRGAS | Sistema de Referência Geocêntrico para as Américas |
| SMAMA..... | Secretaria Municipal Adjunta de Meio Ambiente |
| SMARU | Secretaria Municipal Adjunta de Regulação Urbana |
| SR..... | Sensoriamento Remoto |
| TOA | <i>Top Of Atmosphere</i> |
| UCLA..... | <i>University of California</i> |
| UFV..... | Universidade Federal de Viçosa |
| UTM..... | <i>Universal Transversa de Mercator</i> |
| WGS..... | <i>World Geodetic System</i> |

LISTA DE FIGURAS

| | |
|--|----|
| Figura 1 – Ilustração dos processos básicos utilizados no reconhecimento de padrões empregados na classificação de imagens do sensoriamento remoto..... | 3 |
| Figura 2 – Etapas comuns no tratamento de imagens do sensoriamento remoto. Os elementos evidenciados (traços mais espessos e texto em negrito) indicam as etapas realizadas neste trabalho. | 8 |
| Figura 3 – Recursos hídricos e contornos do limite municipal de Belo Horizonte. | 41 |
| Figura 4 – Curvas de nível com equidistância vertical de 5 metros. | 42 |
| Figura 5 – Quadras originadas do cadastro técnico multifinalitário. | 43 |
| Figura 6 – Eixo das vias terrestres originadas do cadastro técnico multifinalitário..... | 44 |
| Figura 7 – Imagens Padrão <i>QuickBird</i> multiespectrais que definem a área de estudo (Município de Belo Horizonte-MG), em composição de cores naturais (bandas 1, 2 e 3 nas cores azul, verde e vermelha, respectivamente), dispostas em diferentes escalas para melhor apresentação..... | 45 |
| Figura 8 – Variável de ambiente espectral NDVI. Os menores valores são apresentados em tons marrons e os maiores valores em tons verdes..... | 62 |
| Figura 9 – Variável de ambiente topográfica MDEHC, menores valores nas cores em tons de azul escuro e maiores valores em cores avermelhadas..... | 63 |
| Figura 10 – Variável de ambiente topográfica MDD com menores valores nas cores em tons de azul escuro e maiores valores em cores de tons avermelhados. | 64 |
| Figura 11 - Variável de ambiente topográfica MDN com menores valores exibidos em tons escuros de cinza, e maiores valores mostrados em tons claros de cinza. | 65 |
| Figura 12 - Variável de ambiente topográfica MDL cujos menores valores são exibidos em tons de cinza escuro e maiores valores mostrados em tons de cinza claro. | 66 |
| Figura 13 – Ilustração do histograma de valores NDVI para áreas de classes de vegetação mostrando a densidade da distribuição concentrada nos maiores valores. Podem ser verificados ainda alguns parâmetros estatísticos entre os quais, média e desvio padrão. | 69 |
| Figura 14 – Imagem booleana evidenciando áreas de vegetação na cor preta e de não vegetação na cor branca, obtida pelo processo de reclassificação de valores NDVI..... | 70 |
| Figura 15 – Imagens resultantes da RLB, que apresentam valores de probabilidades no intervalo de 0 a 1 em (a) e valores de resíduos no intervalo de -1 a 1 em (b), referentes a floresta nativa. | 75 |
| Figura 16 - Imagens resultantes da RLB referente a floresta plantada, apresentando valores de probabilidades estimadas na escala de 0 a 1 em (a) e valores de resíduos de -1 a 1 em (b). | 76 |
| Figura 17 – Imagens resultantes da análise de RLB referente a classe cerrado, apresentando valores de probabilidade no intervalo de 0 a 1 em (a) e valores de resíduos entre -1 e 1 em (b). | 77 |

| | |
|---|----|
| Figura 18 - Imagens resultantes da RLB da classe campo cerrado, com valores de probabilidades em (a) escalonados de 0 a 1, e, valores de resíduos em (b) escalonados de -1 a 1..... | 78 |
| Figura 19 - Imagens de valores estimados de probabilidade, no intervalo de 0 a 1 em (a) e seus resíduos no intervalo de -1 a 1 em (b), resultantes da análise de RLB para a classe campo plantado. | 79 |
| Figura 20 – Esquema geral do método de introdução de informações contextuais no processo de classificação de imagens de sensoriamento remoto. | 81 |
| Figura 21 – Ilustração das etapas da metodologia de classificação contextual por modelagem indireta do contexto. | 82 |
| Figura 22 – Imagem de áreas de vegetação em quadras (quintais - fundos de lote de áreas assumidas particulares). | 84 |
| Figura 23 – Imagem da vegetação que ocorrem em vias. | 85 |
| Figura 24 – Imagem fundamentada em valores de probabilidade, determinadas pelo modelo probabilístico Bayesiano para a classe de vegetação floresta nativa. | 88 |
| Figura 25 – Ilustração de imagem fundamentada em valores de probabilidades determinada pelo modelo probabilístico Bayesiano para classe floresta plantada. | 89 |
| Figura 26 - Imagem fundamentada em valores de probabilidade determinadas pela aplicação do modelo probabilístico Bayesiano para a classe de vegetação de cerrado. . | 90 |
| Figura 27 - Imagem fundamentada em valores de probabilidade produzida pela aplicação do modelo probabilístico Bayesiano para a classe informacional campo cerrado..... | 91 |
| Figura 28 - Imagem fundamentada em valores de probabilidade determinada pela aplicação do modelo probabilístico Bayesiano para a classe de vegetação campo plantado..... | 92 |
| Figura 29 – Imagem de classes temáticas de vegetação obtida por processo de CMV através da introdução de Informações Contextuais (Classificação Contextual). | 95 |

LISTA DE TABELAS

| | |
|--|----|
| Tabela 1 – Descrição das categorias de vegetação fornecida pelos técnicos da SMAMA dos temas a serem discriminados no mapa temático..... | 40 |
| Tabela 2 – Algumas características descritivas obtidas a partir dos respectivos arquivos de metadados das imagens utilizadas..... | 46 |
| Tabela 3 – Especificações gerais de resoluções de imagens produzidas pelo satélite artificial <i>QuickBird</i> | 49 |
| Tabela 4 – Erros dos Pontos de Controle para as imagens “A”, “B” e “CDE”. | 54 |
| Tabela 5 – Síntese dos dados para atenuação atmosférica. | 57 |
| Tabela 6 – Resumo dos parâmetros da RLB. Para cada classe informacional são apresentadas as variáveis dependentes e independentes, suas respectivas equações de regressão e estatística ROC..... | 73 |
| Tabela 7 – Valores empíricos dos hiperparâmetros α e β (<i>a priori</i>) informados para cada classe na produção das imagens fundamentadas em valores de probabilidade <i>a posteriori</i> | 87 |
| Tabela 8 – Matriz de significância de valores Z calculados para os métodos de Classificação Tradicional e Contextual, bem como seus respectivos valores de coeficientes <i>Kappa</i> e variâncias..... | 94 |
| Tabela 9 – Áreas das classes informacionais obtidas por modelagem direta e indireta (carta-imagem temática) do contexto, expressas em hectares. | 96 |

RESUMO

ASSIS, Leonardo Campos de, M.Sc., Universidade Federal de Viçosa, julho de 2008.

Uso de informações contextuais no processo de classificação de imagens do sensoriamento remoto. Orientador: Carlos Antônio Oliveira Vieira, Co-orientadores: Dalto Domingos Rodrigues, Antônio Simões Silva e Maria Lúcia Calijuri.

A utilização de informações exclusivamente espectrais para classificação de imagens tem se mostrado pouco eficiente frente aos complexos cenários que o avanço tecnológico de observação terrestre oferece. Por esse motivo, a pesquisa apresentada nesta dissertação propõe a consideração de informações contextuais para auxiliar no processo de classificação de imagens digitais do sensoriamento remoto. Para demonstrar a viabilidade da proposta, aplicou-se a metodologia no estudo de caso para determinação de áreas de vegetação no Município de Belo Horizonte – MG. Através de contato com órgãos da Prefeitura de Belo Horizonte, provedores dos dados espaciais, foram estabelecidas as classes informacionais a serem discriminadas pelo processo. Os dados constavam de planos de informação vetoriais e imagens multiespectrais do satélite artificial *QuickBird 2*. Após edição de parte dos dados vetoriais e posterior conversão para o formato *raster*, aliada ao processo de atenuação dos efeitos atmosféricos e ortorretificação das imagens, iniciou-se a aplicação do método. Primeiramente foram levantadas quais informações contextuais seriam úteis à identificação das classes informacionais almeçadas, em seguida realizaram-se procedimentos para se obtê-las. Optou-se então por tratar a modelagem do contexto por meio de duas abordagens distintas: uma direta e outra indireta. A modelagem direta caracterizou-se por operações de intersecção de imagens com tipo de dados booleanos, enquanto a modelagem indireta forneceu a opção de manipular tipos de dados contínuos. A modelagem direta foi aplicada para obtenção da ocorrência de áreas de vegetação em vias e em quadras, conseguida a partir da variável de ambiente espectral NDVI. Após, foi realizada operação de intersecção com imagens de vegetação, de vias e de quadras. Para aplicação da modelagem indireta, as informações contextuais foram definidas para melhor caracterizar tipos de vegetação (floresta nativa; floresta plantada, cerrado, campo cerrado e campo plantado), em termos das variáveis de ambiente

topográficas MDEHC, MDD, MDN, e MDL; e variável da ambiente espectral NDVI. Para cada classe informacional, uma combinação particular de informações contextuais foi estabelecida e utilizada em procedimento de Regressão Logística Binomial, para determinar valores iniciais de maior verossimilhança para sua ocorrência. Desse modo, foram geradas imagens, uma para cada classe informacional, com valores de verossimilhança definidos pela operação de regressão. Aplicou-se então o paradigma Bayesiano, através de modelo probabilístico Bayesiano, para se obter imagens fundamentadas em valores atualizados de probabilidade com base no conhecimento especialista. O modelo probabilístico Bayesiano adotado foi o Beta-Binomial, cuja indexação foi feita pelos valores dos hiperparâmetros α e β , que expressam a opinião do analista acerca da posição e dispersão da distribuição, respectivamente. Os valores adotados para os hiperparâmetros foram obtidos por simulações e iterações, seguidas de análises intermediárias dos resultados, realizadas sucessivamente até que se obtivesse uma representação mais apropriada da realidade. As imagens fundamentadas em valores de probabilidade, determinadas pelo modelo Bayesiano, foram utilizadas como valores iniciais de probabilidade no método de classificação pela máxima verossimilhança. Para verificar a eficácia do método de inclusão de informações contextuais, denominado de Classificação Contextual, comparou-se com o método de Classificação Tradicional pelo algoritmo Classificador da Máxima Verossimilhança. Os resultados dos dois procedimentos foram avaliados por matrizes de contingência, geradas pela comparação entre as imagens temáticas produzidas e uma imagem de referência. A imagem de referência foi obtida a partir das amostras de treinamento refinadas (ou purificadas) pelo algoritmo da distância estatística de *Mahalanobis*, com um valor arbitrado de 50% como critério de semelhança. A partir das matrizes de contingência foi estimado o valor do coeficiente *Kappa*, que apresentou diferença de aproximadamente 6,5% entre os métodos de Classificação, com superioridade para o Contextual (0,9199) em relação ao Tradicional (0,8528). Para certificar que essa diferença foi, contudo, significativa, aplicou-se o teste Z bilateral entre os métodos ao nível de significância de 5%. Pelos valores Z observou-se que, ao nível de confiança de 95%, a hipótese de nulidade (de equivalência entre métodos) foi rejeitada e, portanto, os métodos foram constatados diferentes. Empregou-se então, o método de Classificação Contextual para geração da imagem temática de vegetação do Município de Belo Horizonte - MG. Concluí-se daí que, a partir dos dados disponíveis e hipóteses simplificativas assumidas, o método de Classificação Contextual foi realmente superior ao método de Classificação Tradicional, logo, sua aplicação é recomendada.

ABSTRACT

ASSIS, Leonardo Campos de, M.Sc., Universidade Federal de Viçosa, July, 2008. **Use of contextual information in the remote sensing images classification process.**

Adviser: Carlos Antônio Oliveira Vieira, Co-advisers: Dalto Domingos Rodrigues, Antônio Simões Silva and Maria Lúcia Calijuri.

The exclusive use of spectral information applied to image classification has shown less efficiency through the complex conditions that technological incoming of earth observation offers. For this reason, the research presented on this dissertation purposes to consider the contextual information to help in the remote sensing digital image classification process. To reveal the purpose viability, the methodology was applied in the study case for determination of vegetation areas at Belo Horizonte Municipal District. Through the partnership with some organisms of the Belo Horizonte Administration, the spatial data providers, informational classes to be discovered by the process was determined. The data were composed by vector information layers and *QuickBird 2* artificial satellite multispectral images. After the edition of part of the vector layers data and subsequent conversion to raster format, combined to the atmospheric effects attenuation process and imagery orthorectification, the application of the method was initiated. At first, the helpful contextual information to map categories identification was established, following by the necessary procedures to get them. Two different approaches to deal with the context modeling were chosen: one direct and other indirect one. The direct modeling was featured by images intersection operations with Boolean data types, and, the indirect modeling offered the analyst option to operate continuous data types. The direct modeling was applied to identify the incidence of vegetation areas on streets and blocks, obtained from the spectral environmental variable NDVI. And then, an intersection operation was performed between vegetation image, the streets and blocks layers. To apply the indirect modeling, the contextual information were defined to better featuring the vegetation types (native forest, crop forest, savannah, savannah field and crop field), in terms of the topographic environmental variables HCDEM (Hydrologically Consistent Digital Elevation Model), SDM (Slope Digital Model), NDM (North face Digital Model – also called *Northness*), and EDM (East face Digital Model – also called *Eastness*); and the spectral

environmental variable NDVI. For each informational class, one specific arrangement of contextual information was determined and used on a Binomial Logistic Regression procedure, to find out initial values of higher likelihood for class happening. In this way, images was generated, one for each class, with defined likelihood values defined by regression operation. The Bayesian Paradigm was applied, through the Bayesian probabilistic model, to obtain images founded on updated probability values based on specialist knowledge. Beta-Binomial was the Bayesian probabilistic model adopted. Model index was done by α and β hyperparameters values, expressing the analyst opinion about the distribution position and dispersion, respectively. Values assigned for the hyperparameters has been acquired by simulations and iterations, following by intermediate results analysis, successively made until a proper reality representation was obtained. Imagery founded on probability values, determined by Bayesian model, was used like initial probability values in the maximum likelihood classification method. To verify the efficiency of the contextual information inclusion method, named Contextual Classification process, it was compared against the Traditional Classification method by the Maximum Likelihood Classifier algorithm. Results of both procedures were evaluated by contingency matrixes build by comparison between the thematic imagery produced by the classification methods and the reference image. Reference image was generated from the training sites, refined (or purified) by the *Mahalanobis* statistical distance algorithm, employing a 50% arbitrary value threshold of similarity criterion. From the contingency matrixes, *Kappa* coefficient value was estimated, presenting a difference about 6.5% between the Classification methods, indicating superiority of the Contextual (0.9199) one, in relation to Traditional (0.8528) one. To certify that the difference was, although, significant, a two-sided *Z* test was applied among the methods at 5% significance level. By *Z* values obtained, was observed that, at 95% confidence level, the nullity hypothesis (equivalency between methods) must be rejected and, thus, the methods were verified different. Consequently, the Contextual Classification method was employed to generate the vegetation thematic image of Belo Horizonte (MG) Municipal District. Results show that, from the available data and through the simplification hypothesis assumed, the Contextual Classification method purposed was really superior to the Traditional Classification method and, thus, its application is recommended.

1. INTRODUÇÃO

Ao mesmo tempo em que o Brasil é um país de dimensão territorial extensa, fortemente caracterizado por um perfil agrícola marcante em constante desenvolvimento, também abriga cidades de grande porte que apresentam cenários complexos de ocupação territorial. Características que exigem do país um perfil dinâmico no que se refere ao melhoramento das políticas de ocupação territorial e de uso do solo, nos âmbitos agrário, urbano e de conservação natural. Seja para conhecer as possibilidades de exploração envolvidas, seja para planejar a ocupação de maneira eficiente, ambos demandam contínua investigação e desenvolvimento de tecnologias para subsidiar gestores com informações estratégicas acerca das áreas, no intuito de facilitar seu gerenciamento. Imagens produzidas por sensores acoplados a plataformas orbitais (satélites artificiais) se consolidam como fonte de observação eletromagnética, capaz de atender com agilidade diversos segmentos provendo informações atualizadas a respeito da ocupação dos espaços terrestres. Convenientemente associadas a bases de dados existentes, com Sistemas de Informações Geográficas (SIG), as imagens digitais produzidas pelo Sensoriamento Remoto (SR) tornam-se elementos importantes no processo de tomada de decisão.

Entretanto, a informação disponível na imagem, por si só, muitas vezes não se apresenta em formato inteligível. Pode ser devido a fatores externos diretamente associados ao mecanismo de obtenção, como características próprias do tipo de sinal observado. Caso em que a imagem deve ser submetida a processos e tratamentos específicos para que seus elementos apresentem significado relevante. Esses processos e tratamentos constituem fértil campo de investigação e estudos do Sensoriamento Remoto.

O presente trabalho se ocupa em apresentar os processos realizados em imagem de satélite da área do Município de Belo Horizonte - MG. São descritos os processos que se aplicam ao pré-processamento (para ajuste de inconsistências na imagem) e o processo que tem por finalidade reconhecer objetos categóricos associados a temas de interesse (classificação).

Para o processo de classificação é proposta uma metodologia que busca melhorar seus resultados, em áreas onde esses não são satisfatórios, de modo a considerar

informação externa adicional, como condições de relevo e vegetação da área, fundamentada pelo conhecimento especialista, que deve auxiliar a descrever com maior propriedade o contexto envolvido na análise.

1.1 Caracterização do problema.

Para que imagens temáticas obtidas com procedimentos de tratamento possam ser utilizadas com segurança em análises espaciais, faz-se necessário conhecer sua qualidade associada resultante e espera-se que esta qualidade atenda a padrões pré-estabelecidos. Necessidade que leva ao desenvolvimento e aprimoramento das metodologias referentes ao processo de classificação de imagens, bem como dos métodos de avaliação da qualidade. No início da década de 80 já se realizavam estudos no intuito de melhorar a exatidão do processo de classificação de imagens através da combinação de conteúdo espectral e externo (MATHER, 2004, p. 240). Mather (1999) cita um trecho da apresentação oral de G.G. Wilkinson em julho de 1996 na *York University*, que diz: “a exatidão da classificação raramente excede 80% e este valor deve representar um limite superior a exatidões obtidas por dados do sensoriamento remoto”. Evidente que esse valor deixa a desejar e suscita à investigação de novas maneiras de se elevar esse patamar de exatidão. Avanços significativos foram alcançados com aperfeiçoamento das regras decisórias através de sofisticadas metodologias (modelos matemáticos complexos, cognição artificial, entre outros) nos últimos anos. Embora o que se tenha conseguido na prática sejam diferenças pouco significativas na medida de desempenho avaliada. Alesheikh *et al.* (2003) mencionam que o valor numérico do pixel é resultado de observação e, portanto, está sujeito a discrepâncias associadas (como qualquer observação). Mather (1999) acrescenta que uma fonte de problemas associados a piores resultados com a classificação são devidos a uma inapropriada escala de observação do objeto analisado. Além dessas discrepâncias e fontes de problemas, há o fato de, na maioria das vezes, a imagem ser constituída por mais classes informacionais (categorias temáticas) do que se pretende classificar.

Para entender melhor o problema, pode-se analisar o processo de automação no reconhecimento de padrões empregado na classificação de imagens, que se inicia pela

descrição dos objetos. Em seguida, colecionam-se características que definam seu padrão. A partir dessas características são obtidos parâmetros que subsidiam determinada regra de decisão para tentar identificar e diferenciar as classes temáticas. Por fim, realiza-se a validação da qualidade obtida com o procedimento, verificando se esta atende a critérios pré-estabelecidos. Na ilustração da Figura 1 são apresentados os processos de reconhecimento de padrões empregados na classificação de imagens.




Figura 1 – Ilustração dos processos básicos utilizados no reconhecimento de padrões empregados na classificação de imagens do sensoriamento remoto.

É importante entender em que etapa do processo de reconhecimento de padrões está a questão problemática que configura a barreira quase limitante, no que se refere à qualidade obtida com avaliação da classificação de imagens. Argumenta-se que uma decisão acertada seja determinada pela qualidade da informação usada para subsidiá-la. Além disso, conjectura-se que apenas a informação espectral seja ineficiente para discriminar as classes informacionais em cenários mais complexos de composição da paisagem. Aparentemente, a fonte do problema está na etapa de extração de características da fonte de dados iniciais (nos valores numéricos dos pixels), e na limitação da informação exclusivamente espectral como discriminante.

1.2 Motivação e justificativas.

Investigações que buscam melhores resultados para a classificação de imagens orbitais têm sido feitas desde a obtenção das primeiras imagens do SR. Muitos avanços foram alcançados desde então, entretanto, a qualidade da exatidão temática constitui, ainda hoje, uma restrição para o uso e aplicação de todo potencial fornecido pelo SR orbital. Diante desse contexto, as considerações que podem ser apresentadas para fundamentar a motivação da presente proposta são as seguintes:

- (i) embora a utilização de informações exclusivamente espectrais para classificação de imagens tem sido exaustivamente explorada, seus resultados ainda deixam a desejar;
- (ii) procedimentos de classificação convencionais têm oferecido piores índices de avaliação dos mapas temáticos quando as categorias discriminadas são de ordem mais complexa (sensoriamento remoto urbano);
- (iii) apesar da busca por melhores resultados com a utilização de dados externos como fonte de informação adicional não ser recente (MATHER, 2004, p. 240) no processo de classificação, acredita-se que o tema ainda não tenha sido explorado de forma consolidada.

Para casos de aplicações mais simples, de extensas áreas homogêneas (culturas agrícolas, reflorestamento, entre outras), acredita-se que os procedimentos convencionais adotados para a classificação de imagens têm sido suficientes e adequados por longo período de tempo. Contudo, o desenvolvimento tecnológico de observação terrestre evoluiu e ampliou seu horizonte de possibilidades, através dos seus produtos de imagens. Com isso, a realidade atual apresenta novas necessidades de reconhecimento da superfície, para as quais os procedimentos convencionais de classificação têm sido limitados. Este trabalho tem sua justificativa na proposta de utilizar informação contextual, em adição à informação espectral, para o processo de classificação de modo que sua aplicação estenda a cenários mais complexos de uso e ocupação do solo.

1.3 Hipótese de pesquisa.

Malpica *et al.* (2007) e Laha *et al.* (2006) apontam para a idéia de que a escolha de uma determinada metodologia em detrimento de outra deve ser feita considerando seu desempenho verificado para uma aplicação específica, pois uma determinada metodologia que foi bem sucedida para uma situação em especial não será necessariamente em outra. A variação de desempenho de determinada metodologia ocorre em função do caso analisado. Nesse sentido, o pensamento que considera apenas a informação espectral como capaz de distinguir, eficientemente, entre diversos tipos de

cobertura da superfície terrestre é uma maneira inadequada de perceber e considerar os inúmeros fatores envolvidos na constituição da paisagem (DANIELS, 2006). Além disso, ao trabalhar no contexto espectro-temporal, Braga (2007) sugere em suas conclusões que uma classificação contextual antes da Classificação Tradicional, retirando classes informacionais diferentes das classes-objetivo (área urbana, estradas, entre outras), poderia ser benéfica ao processo. Tais considerações conduziram à seguinte hipótese de pesquisa:

“É possível melhorar a qualidade dos produtos da classificação de imagens do sensoriamento remoto através da inclusão de informações contextuais espaciais ao procedimento.”

1.4 Objetivo.

O objetivo geral desse trabalho é identificar alguns tipos de vegetação específicos que ocorrem na área do Município de Belo Horizonte – MG, através da classificação de imagens do satélite *QuickBird 2*. A quantificação e localização espacial das áreas de vegetação deverão subsidiar a municipalidade na determinação do indicador **área verde**, componente da variável **meio ambiente**, necessária para determinação do Índice de Qualidade de Vida Urbana de Belo Horizonte (IQVU-BH)¹. Para isso, propõe-se aplicar uma metodologia para melhorar a exatidão do processo de classificação de imagens orbitais através da introdução de conhecimento por meio de informações contextuais.

Mais especificamente, a metodologia conta com duas abordagens, uma para modelagem direta e outra para modelagem indireta do contexto. Para as classes informacionais que não são obtidas automaticamente pela classificação, sugere-se o processo de modelagem direta do contexto para obtê-las.

¹ Trata-se de um índice espacial que surgiu em 1996, composto por 81 Unidades de Planejamento (geoespaciais) em Belo Horizonte e se configura como ferramenta de instrumentalização da gestão pública. Apresenta alta complexidade na sua determinação e envolve multiplicidade de áreas na sua composição. Objetiva fornecer subsídios à administração pública para uma equanimidade da distribuição de recursos de maneira eficiente. Abrange 11 variáveis (Abastecimento, Assistência Social, Cultura, Educação, Esportes, Habitação, Infra-Estrutura, Meio Ambiente, Saúde, Serviços Urbanos e Segura Urbana) compostas por 29 componentes formadas por 75 indicadores. Maiores detalhes podem ser consultados em Nahas (2000).

Espera-se, com a modelagem indireta, utilizar as informações contextuais para produzir uma imagem fundamentada em valores de probabilidades para cada classe informacional de vegetação, em etapa anterior à regra de decisão. Com isso, o algoritmo classificador escolhido deverá contar com mais informações para operar nas áreas (pixels) efetivas de maior probabilidade de ocorrência das categorias-objetivo, reduzindo o nível de confusão e, conseqüentemente, elevando a qualidade da imagem temática gerada. O conhecimento introduzido pelas informações contextuais, de maneira matemática através de recursos de Inferência Bayesiana, deve contribuir para redução de problemas de classificação de imagens em ambiente urbano. Por fim, pretende-se validar a metodologia de modelagem indireta do contexto pela avaliação da qualidade da imagem temática gerada, comparando-a com outra imagem produzida pelo método de Classificação Tradicional da máxima verossimilhança. Segundo literatura especializada (DOMAÇ e SÜZEN, 2006; CAYUELA *et al.*, 2006; DANIELS, 2006), o método de classificação da máxima verossimilhança é amplamente utilizado como método de referência para comparação com outros métodos, e por esse motivo foi escolhido.

1.5 Organização

A organização da dissertação foi estruturada em capítulos. O capítulo 1 apresenta o problema e as motivações que levaram ao fundamento da hipótese de pesquisa bem como seus objetivos; o capítulo 2 contextualiza as metodologias empregadas no pré-processamento de imagens e explora a introdução do conhecimento em termos de informações contextuais através de recursos de Inferência Bayesiana; o capítulo 3 explica as etapas de aplicação da metodologia e reporta as dificuldades observadas; o capítulo 5 exhibe e discute os resultados obtidos; o capítulo 6 faz as considerações conclusivas através do exame das potencialidades e problemas constatados, bem como aponta algumas possíveis direções viáveis para sua continuação.

2. REVISÃO DA LITERATURA E FUNDAMENTAÇÃO TEÓRICA.

2.1 Características das imagens de satélite.

A imagem de satélite é formada por elementos com valor numérico associado chamados pixel (*PI*cture *X* *E*LEment) ou células, que são agrupados contiguamente assumindo uma estrutura matricial. Seus valores são resultado do processo de medida da intensidade de Radiação Eletromagnética (REM) em faixas de valores pré-determinadas desse espectro (bandas espectrais), correspondentes a alvos específicos na superfície terrestre. A REM é reconhecida por sensores que são capazes de registrar informação em diferentes comprimentos de onda simultaneamente, podendo fornecer um perfil abrangente em diferentes resoluções espectrais.

Sensores orbitais estão a bordo de plataformas orbitais encontradas em altitudes acima da atmosfera terrestre. Suas características (tipo de órbita, resoluções espacial, espectral, radiométrica e temporal) são definidas inicialmente para atender aos requisitos da missão para qual foram projetados (monitoramento da Terra, investigação de fenômenos atmosféricos e marinhos, entre muitos outros), no entanto, sua efetiva aplicação é comumente estendida a outros objetivos, além dos idealizados na concepção do projeto. Dentre os tipos de órbitas têm-se as geoestacionárias e também as polares. Menos comuns, as órbitas geoestacionárias caracterizam-se por realizar sua varredura sempre na mesma porção da superfície, sua trajetória caracteriza-se por acompanhar o movimento de rotação terrestre. Órbitas Polares são mais comuns, síncronas com o Sol, garantem que a varredura seja sempre realizada na superfície terrestre iluminada pelo Sol. Muitos satélites utilizam órbitas quase polares, síncronas com o Sol, pelo fato do ângulo azimutal solar ser o mesmo para cada data de observação, variando apenas durante o ano (MATHER, 2004). Além disso, as órbitas polares síncronas com o Sol são justificadas pela característica passiva dos sensores ópticos, que necessitam de fonte externa de REM, cuja maior fonte é o Sol.

Quanto às resoluções disponíveis, a espectral indica o intervalo de sensibilidade a determinados comprimentos de onda do espectro eletromagnético no qual o sensor atua, medida em unidades submétricas (mais usualmente, o micro - μm). Resolução espacial

faz referência à menor unidade de área da superfície detectável pelo sensor inequivocamente, usualmente medida em unidades métricas e seus múltiplos (recentemente o centímetro, mas, usualmente metros ou quilômetros). Resolução temporal diz respeito ao tempo de retorno da plataforma orbital a uma mesma visada nadir ou visada lateral, informando qual a periodicidade de varredura sobre determinado local na superfície (usualmente medida em dias). Resolução radiométrica se refere à capacidade de reconhecimento de níveis distintos de intensidades de energia eletromagnética num determinado intervalo (medida em bits, na forma: 2^n , em que n é o número de bits).

Entre as faixas (bandas) espectrais, aquelas próximas a região óptica (visível) são sujeitas a maior interferência de componentes atmosféricos que causam efeitos perturbadores como absorção por gases e espalhamento por moléculas e aerossóis. Esses efeitos perturbadores integram o sinal recebido de forma indesejável, sendo necessários procedimentos para sua eliminação ou redução do seu efeito. Diante dessas características mencionadas, pode-se imaginar que há várias fontes de distorções que impactam na produção das imagens. Discrepâncias na geometria do pixel podem ser conseqüências do movimento da Terra, atitude do satélite no percorrer de sua órbita, defeitos de alinhamento dos sensores decorrentes do lançamento, dentre outras. As correções dos efeitos atmosféricos e imperfeições geométricas são consideradas na etapa de pré-processamento de imagens. As operações de correção são usualmente as primeiras realizadas, e podem incluir operações qualitativas de suporte para fins de fotointerpretação, como as de ajuste de realce, contraste, manipulação de histograma, dentre outras. Algumas dessas operações destinam a melhorar o efeito visual das imagens e são temas estudados no campo do SR qualitativo. A ilustração da Figura 2 exhibe, em termos gerais, as etapas mais comuns de tratamento de imagens orbitais e nos componentes em evidência, as etapas que foram realizadas neste trabalho.




Figura 2 – Etapas comuns no tratamento de imagens do sensoriamento remoto. Os elementos evidenciados (traços mais espessos e texto em negrito) indicam as etapas realizadas neste trabalho.

2.2 Correção geométrica e ortorretificação.

Com o intuito de caracterizar apropriadamente a base de dados, optou-se por fazer uma breve introdução sobre os sistemas de referência que estão associados a ela, uma vez que os Planos de Informação (PI) vetoriais e as imagens *QuickBird* encontram-se em diferentes sistemas.

Para produção de cartas e mapas através da realização de levantamentos em caráter oficial para fins legais diversos no Sistema Geodésico Brasileiro (SGB), é necessário que as coordenadas estejam relacionadas a um sistema de referência oficial (GONÇALVES, *et al.* 2007a). No Brasil, houve recentemente, no ano de 2005, uma alteração no dispositivo legal que dispõe sobre o Sistema de Referência Oficial Brasileiro por meio da Resolução Presidencial R.PR 1/2005. O sistema de referência antigo (atualmente ainda é válido para fins de transição) era o *Datum* Sul-Americano de 1969 ou SAD 69 (*South American Datum 1969*), e o novo trata-se do Sistema de Referência Geocêntrico para as Américas ou SIRGAS 2000 que, para fins de engenharia, é equivalente ao sistema de referência utilizado para as imagens orbitais *QuickBird 2*, o Sistema Geodésico Mundial de 1984 ou WGS 84 (*World Geodetic System 1984*). A principal diferença entre os sistemas está em sua concepção: enquanto o SAD 69 (sistema de referência associado à base de dados vetorial, aerolevantada na década de 80) é um sistema quase geocêntrico que possui sua origem próxima ao centro de massa da Terra, o WGS 84 (sistema de referência associado às imagens *QuickBird*) e o SIRGAS 2000 são sistemas geocêntricos, que possuem sua origem no centro de massa Terrestre (MONICO, 2000). Apesar da representação de características por meio das coordenadas geodésicas (Latitude, Longitude e Altura Geométrica) ser mais adequada para realização de cálculos, a representação cartográfica em uma projeção plana tem sido requisitada por inúmeras entidades e para diversos propósitos (GONÇALVES, *et al.* 2007a). Atualmente, a mais utilizada é a Projeção Universal Transversa de Mercator (UTM) com coordenadas Este e Norte referenciadas a um Meridiano Central ou a um Fuso e ao Hemisfério.

A correção geométrica tem por objetivo corrigir as imagens de distorções geradas no instante de aquisição da cena. Conforme Mather (2004) a correção pode ser justificada por diversas circunstâncias, como por exemplo, transformar uma imagem para coincidir com um mapa; localizar pontos de interesse no mapa e na imagem; sobrepor seqüências de imagens temporais da mesma área, talvez obtidas por diferentes sensores; sobrepor imagens e mapas em um SIG. Conforme Toutin (2006), as fontes de discrepâncias comuns, capazes de provocar distorções nas imagens podem ser agrupadas como sendo:

- (i) da plataforma: variações na atitude;
- (ii) do sensor: variações na mecânica (intervalo e velocidade de varredura, entre outros); distorções da lente (focal, descentralização, entre outros); ângulos de visada/observação; efeito panorâmico com campo de visada;
- (iii) dos instrumentos de medida: variações temporais ou de rumo; sincronia do relógio;
- (iv) da atmosfera: refração e turbulência;
- (v) da Terra: efeito topográfico, da curvatura e rotação;
- (vi) de mapa: do geóide para o elipsóide e deste para mapa.

Além das imagens do sensoriamento remoto produzidas por espelho de varredura (sujeitas a variações mecânicas), há também aquelas produzidas por uma matriz de dispositivos de carga acoplados, comumente conhecidos pelo acrônimo CCD (*Charge Coupled Device*), que operam pelo princípio do efeito fotoelétrico² (inclusive as de maior resolução espacial). Com o advento dessas imagens, as técnicas de correção geométrica do SR tem se assemelhado muito às técnicas empregadas na Fotogrametria (MATHER, 2004). Facilidade na identificação de feições e no processamento automatizado de cálculos para o processo de correção geométrica são vantagens que viabilizam a integração de variáveis que eram desprezadas anteriormente, segundo Marotta *et al.* (2007). Para exemplificar citam as incertezas associadas às coordenadas de referência, decorrentes tanto da qualidade das observações em campo como dos parâmetros de transformação do modelo computados a partir de determinado número

² A colisão de fótons (luz) contra a superfície do sensor induz a liberação de elétrons que geram uma corrente elétrica e esta varia de intensidade através da quantidade de elétrons liberada conforme comprimento de onda específico. A intensidade é então convertida em formato digital e armazenada em determinada posição na matriz CCD cuja célula corresponde à menor porção distinguível da superfície quando observada (SANTOS, 2003).

dessas observações. Neste trabalho eles propõem uma metodologia robusta para considerar as variâncias das observações de campo propagadas para o pixel, de maneira a distribuir espacialmente as incertezas e torná-las visualmente acessíveis através de uma imagem contínua do erro. Um dos benefícios obtidos com o resultado da correção geométrica é o conhecimento da posição mais provável do pixel no terreno, com uma incerteza associada. A incerteza do ajustamento do posicionamento do pixel é usualmente medida em termos do erro médio quadrático (*Root Mean Square - RMS*), podendo ser total (para a imagem toda) ou individual (para cada pixel – método proposto por Marotta *et al.* (2007)). O RMS total descreve a divergência posicional típica de todos os pixels em relação à equação de ajustamento escolhida, fornecendo a probabilidade que uma posição mapeada terá de variar a partir da sua posição verdadeira. Conforme os padrões nacionais de exatidão norte-americanos, os RMS para imagens devem ser menores que a metade da resolução espacial (tamanho do pixel) da imagem a ser corrigida (EASTMAN, 2006, p.273) e é geralmente expresso nas mesmas unidades de referência da imagem submetida à correção.

Segundo Okeke (2006), opções comuns de transformação de imagens são a polinomial, a projetiva, a diferencial e o modelo de função racional. Pode haver ainda a correção do modelo do sensor e a reprojeção da ortorretificação. O autor faz uma revisão sobre o tema, apresenta o fluxo de etapas do processo de ortorretificação e comenta cada modelo e suas características. A ortorretificação é o processo de transformação da projeção da imagem (em caso de aerofotografias, a projeção é central) em visada ortogonal da superfície, removendo os efeitos de distorção e do terreno (OKEKE, 2006). Conforme atesta Fraser *et al.* (2006), um dos modelos mais promissores para correção de imagens de maior resolução espacial é o modelo de razão dos coeficientes polinomiais (*Rational Polynomial Coefficients – RPC*) que tem sido universalmente aceito e validado para orientação dessas imagens. Este modelo requer o uso de arquivos RPC (disponibilizados pelo distribuidor de imagens como parte do conjunto de metadados), que contêm os coeficientes racionais da função polinomial relativos a parâmetros de atitude e orientação exterior do sensor, gerados no momento de aquisição da imagem, e que, aliados aos pontos de controle coletados na superfície, permitem determinar sua orientação interior (detalhes sobre orientação interior e exterior de imagens de alta resolução podem ser verificados em Jacobsen (2005) e Toutin (2006)). Esses parâmetros de correção do sensor aliados a um modelo de apoio altimétrico permitem calibrar o modelo de correção geométrica com maior flexibilidade

para obter melhores resultados, sendo possível reduzir distorções causadas pela topografia do terreno e conseguir a ortorretificação da imagem.

Para processar a correção geométrica a Função Racional processa uma transformação entre coordenadas nos espaços imagem $P(i,j)$ e objeto $P(X, Y, Z)$, através da razão entre polinômios (NIU *et al.*, 2004; FRASER *et al.*, 2006), conforme:

$$\begin{cases} i = \frac{P_1(X, Y, Z)}{P_2(X, Y, Z)} \\ j = \frac{P_3(X, Y, Z)}{P_4(X, Y, Z)} \end{cases} \quad (1)$$

em que $P_i(i = 1, 2, 3, 4)$ tem a forma geral:

$$\begin{aligned} P(X, Y, Z) = & a_1 + a_2X + a_3Y + a_4Z + a_5XY + a_6XZ + a_7YZ + a_8X^2 + a_9Y^2 + \\ & a_{10}Z^2 + a_{11}XYZ + a_{12}X^3 + a_{13}XY^2 + a_{14}XZ^2 + a_{15}X^2Y + a_{16}Y^3 + a_{17}YZ^2 + \\ & a_{18}X^2Z + a_{19}Y^2Z + a_{20}Z^3 \end{aligned} \quad (2)$$

Ao substituir a Equação (2) em P_i da Equação (1) e simplificar, tem-se um polinômio de 40 (quarenta) coeficientes, 20 (vinte) no numerador e 20 (vinte) no denominador, para a normalização da linha e o mesmo número para coluna. Isto requer um mínimo de 40 (quarenta) Pontos de Controle para solução do modelo uma vez que cada 1 (um) ponto gera 80 (oitenta) coeficientes (NIU *et al.*, 2004).

2.3 Correção ou atenuação atmosférica.

Embora o termo correção atmosférica seja usualmente empregado no SR para designar métodos e processos de melhoria da radiometria do pixel, pela tentativa de eliminação ou redução da interferência atmosférica, acredita-se que, devido à complexidade dos fenômenos que compõem o meio atmosférico, o termo mais apropriado seria atenuação atmosférica, uma vez que se supõe que tais fenômenos sejam impossíveis de serem eliminados. Segundo Vianello e Alves (1991), pode-se pensar na atmosfera como uma máquina térmica que tem como principal fonte de calor a radiação solar, convertendo-a em energia mecânica com baixo rendimento através dos princípios

termodinâmicos. Da quantidade total de REM incidida na superfície, parte é absorvida, parte transmitida e parte refletida. Para o sensoriamento remoto o maior interesse está na interação da REM com a superfície, pois boa parte dos sensores é projetada para reconhecer a porção emitida e refletida dessa energia. A parte de REM originada do Sol que passa através da atmosfera (e interage) incide na superfície (interage com os diversos tipos de materiais diferentemente) e retorna (interagindo novamente) através da atmosfera ao espaço até o sensor. As diferentes formas de interação da REM com os diversos materiais da superfície permitem a identificação e discriminação dos objetos e fenômenos que compõem a paisagem. Por exemplo, a água limpa reflete muito pouco na região óptica do visível, e praticamente nada na região do infravermelho. Valores mais elevados de reflectância registrados nesse comprimento de onda indicam a presença de outros materiais em suspensão na água. Já os solos secos aumentam sua reflectância à medida que aumentam os comprimentos de onda, refletindo mais na região do infravermelho que na região do visível. Na região óptica visível, os tipos de vegetação caracterizam-se por refletir pouco na região do azul, aumentar consideravelmente sua reflectância na região do comprimento de onda da cor verde, e reduzir significativamente em seguida, na região do vermelho. Ao deixar a região óptica do visível e entrar na região do infravermelho próximo, os tipos de vegetação aumentam bruscamente sua reflectância.

Os efeitos perturbadores para energia refletida ao interagir na atmosfera são a absorção por gases e o espalhamento por moléculas (espalhamento molecular). O espalhamento em condições ideais (atmosfera sem nuvens e partículas esféricas) pode ser adequadamente descrito em função contínua do comprimento de onda pelas Teorias de *Rayleigh* e *Mie*. A teoria de *Rayleigh* é aplicada para partículas com raio menor que o comprimento de onda. Quando as partículas são maiores que o comprimento de onda, a teoria de *Mie* é mais apropriada, onde todos os comprimentos são potencialmente espalhados. O efeito aerossol influencia no fenômeno de absorção que, diferentemente do espalhamento, é seletiva (VIANELLO e ALVES 1991; LIANG, 2004) quanto aos agentes absorvedores (como oxigênio, ozônio, vapor d'água, dióxido de carbono, metano e óxido nítrico) da REM, em várias faixas do espectro através dos estágios da energia rotacional (absorção ou emissão de fótons a baixa frequência), vibracional (absorção no infravermelho próximo) e transição eletrônica (absorção e emissão na região do visível e ultravioleta) (VERMOTE, 1997b). Conforme afirma Pinto (2001), no estágio de transição eletrônica os gases influenciam na visibilidade, que exibe correlação direta com a umidade relativa do ar, por meio de mudanças nas propriedades

físicas que ocorrem nos aerossóis. Pinto (2001) menciona ainda que a interferência da umidade na visibilidade pode ser desconsiderada para valores de umidade relativa do ar abaixo de 60%, com significativa sensibilidade à interferência constatada somente a partir de valores de 70 ou 80%.

Como a distância Terra-Sol varia ao longo do ano por motivo de efeitos astronômicos (movimento de Translação da Terra), estimar a intensidade de REM incidente no topo da atmosfera não é problema, visto que basta calcular seu valor para cada dia do ano. Logo, o problema está na atmosfera, pois se trata de um agente complexo que requer atenção especial no tratamento de imagens orbitais. Para isso, alguns métodos são investigados e empregados para redução dos seus efeitos. Mather (2004) explica que o fluxo de radiação eletromagnética registrado em um pixel contém informação sobre:

- (i) a natureza do material na superfície da Terra presente na área do pixel;
- (ii) a posição topográfica da área do pixel;
- (iii) o estado da atmosfera por onde a energia percorre.

Abordando a atenuação atmosférica e suas dificuldades, Mather (2004, p.108) diz: *“dada esta gama de problemas, alguém pode ser tentado a concluir que o sensoriamento remoto quantitativo é a arte de impossível”*.

Apesar da dificuldade ao tratar do tema atenuação atmosférica, sofisticados modelos matemáticos têm sido explorados, aplicados e discutidos por alguns autores como Tanré *et al.* (1990), Vermote *et al.* (1997a), Vieira (2000), Liang (2004), Mather (2004), Wu *et al.* (2005), Tachiiri (2005), apresentando suas opiniões e resultados. Vieira (2000) aborda a correção radiométrica do pixel, que inclui a correção de efeitos atmosféricos, em três passos: (i) calibração do valor do pixel para valor de radiância; (ii) conversão de valor de radiância para valor de reflectância aparente (registrada pelo sensor) e (iii) transformação da reflectância aparente para reflectância da superfície através da correção atmosférica. Wu *et al.* (2005) avaliam três algoritmos consolidados com o mesmo propósito (DOS - *Dark object subtraction*, COST - *Cosine Approximation Model* e AR - *Apparent Reflectance Model*) em imagens *QuickBird* e comparam as reflectâncias espectrais resultantes com medições em campo. Resultados do modelo DOS-COST apontam para superestimação nas bandas da região óptica e subestimação na região do infravermelho próximo. Condições geométricas do satélite influenciaram superestimação para valores de transmitância em todas as bandas quando os ângulos zenital solar ou de visada foram menores que 40 graus em áreas úmidas e

subestimação quando eles foram maiores que 25 graus, em regiões áridas. Concluem que o método não foi eficiente na região do infravermelho próximo, o que conduziu-os a produzir um mapa de curvas de contorno para interpolar a transmitância atmosférica nessa região do espectro, tamanha sua importância para estudos com vegetação. Tachiiri (2005) empregou o modelo 6S (*Second Simulation of the Satellite Signal in the Solar Spectrum*) para correção atmosférica de imagens NOAA/AVHRR (*National Oceanic and Atmospheric Administration/Advanced Very High Resolution Radiometer*) utilizadas para produção de mapas NDVI (*Normalized Difference Vegetation Index*). Comparou os mapas produzidos antes e após o processo, através de análise de regressão, e percebeu que os valores de NDVI em regiões de vegetação muito densa são mais sensíveis a correção. Tachiiri (2005) concluiu que o NDVI aumentou, acompanhando a correção atmosférica, especialmente nos pixels com maiores valores.

O modelo 6S apresentado por Vermote *et al.* (1997a), derivado do modelo 5S proposto por inicialmente por Tanré (1990), permite que os valores de entrada dos dados sejam fornecidos pelo próprio analista, ou através de valores pré-estabelecidos em um banco de dados do programa. Valores de referência e respectivas descrições estão disponíveis em Vermote *et al.* (1997b), Antunes (2001) e NCAVEO (2005), entre outros. A partir dos valores dos parâmetros de entrada, o programa processa também parâmetros de saída, os imprime em um arquivo texto e em seqüência realiza a atenuação atmosférica na imagem. O modelo 6S é robusto e pode ser precisamente ajustado, pois permite a entrada de parâmetros de várias formas diferentes, para simular diversas condições atmosféricas atuantes na tomada da imagem. Devido sua diversidade, é inviável mencionar todas suas configurações admissíveis. Para detalhes mais específicos, consultar Vermote *et al.* (1997b).

2.4 Classificação de imagens.

A classificação de imagens consolida-se na produção de mapas temáticos para diversos fins (como uso do solo e cobertura vegetal, identificação de culturas agrícolas, levantamento de áreas de risco, monitoramento de áreas degradadas, inventários florestais, planejamento regional, entre outros) provocando verdadeira disseminação do emprego da tecnologia. Segundo Mather (2004), a classificação de imagens ocorre em

duas etapas, na primeira pelo reconhecimento de categorias de objetos do mundo real e na segunda através da rotulação dos pixels que representam essas categorias. A imagem temática configura-se como um dos usos mais freqüentes e comuns para imagens de satélite. Entre os processos de classificação, podem ser considerados os mais triviais o supervisionado e o não-supervisionado, e sua diferença é encontrada na primeira etapa da classificação. Enquanto o processo supervisionado utiliza-se do conhecimento do analista para reconhecer *a priori* os objetos do mundo real, no outro o reconhecimento é feito automaticamente por computador. A partir de então a classificação é semelhante para as duas técnicas, pois, em ambas, a rotulação dos pixels é fundamentada em determinada regra de decisão que atua conforme parâmetros obtidos de amostras coletadas na primeira etapa, de reconhecimento das categorias de objetos do mundo real. A classificação é dita híbrida quando reúne características dos dois processos. No entanto, erros presentes nos dados iniciais (pixels) podem se propagar para o produto final (imagem temática) obtido pela classificação. Alesheikh *et al.* (2003) argumentam que os valores numéricos dos pixels são influenciados por algumas fontes de discrepâncias tais como:

- (i) durante a aquisição dos dados – a atmosfera como meio de transformação energética alterando o valor do brilho do pixel por absorção e espalhamento;
- (ii) relativos à natureza dos dados – diferentes materiais da superfície podem ser distinguidos por diferenças muito sutis nas suas respostas espectrais; a influência dos pixels adjacentes nos valores de brilho individuais; a inadequada forma de representação retangular do pixel para certos tipos de cobertura do solo;
- (iii) durante o processo de classificação – os classificadores convencionais ignoram erros nos dados (assumem condições ideais) e geralmente não permitem incorporar outro tipo de informação (não espectral) no processo.

Metodologias têm sido desenvolvidas para serem aplicadas em todas as fases de classificação, com o propósito de reduzir as discrepâncias. Não obstante os avanços alcançados, a correta identificação dos fenômenos que compõem a paisagem terrestre consiste ainda em árdua tarefa, devido tanto às características de constituição do meio bem como as interferências inerentes. A cobertura terrestre que compõe a superfície natural ocorre da relação entre vários fenômenos (naturais ou não) associados ao seu contexto, em diferentes intensidades e determinado espaço geográfico. A classificação chamada multiespectral utiliza a informação espectral de um alvo (objeto na superfície)

registrada em várias bandas na tentativa de distingui-lo inequivocamente. Contudo, em circunstâncias onde a paisagem exhibe cenário complexo quanto à sua composição, apresentando variações espectrais sutis entre classes informacionais, o processo convencional geralmente não satisfaz, gerando imagem temática com graves inconsistências de rotulação. Conforme a opinião de Yashon *et al.* (2006), a melhora na disponibilidade de sensores com maior resolução espacial e espectral não implica necessariamente no aumento da exatidão de produtos da classificação multiespectral, em parte pela quantidade de informação adicional associada à falta de metodologias consistentes capazes de explorar eficientemente o grande volume de dados. Pode ser benéfico então pensar nos métodos de classificação de imagens como complementares ao invés de pensá-los como concorrentes entre si (MATHER, 2004, p. 327).

Um importante fator que atua na qualidade da classificação é a estratégia de amostragem, pois podem influenciar na extração de características das classes que se pretende discriminar, de maneira tendenciosa ou não (a depender do esquema utilizado). As estratégias mais comuns de amostragem são: a agrupada; a aleatória simples; a aleatória estratificada; e a sistemática, segundo Gruijter (1999). Menciona ainda que as estratégias agrupada e sistemática apresentam características de tendência, enquanto as outras, aleatória simples e aleatória estratificada, não. Em complemento, a aleatória estratificada é mais vantajosa do que a aleatória simples por restringir a aleatoriedade em estratos que garantem a cobertura por toda a área. Apesar disso, um estudo comparativo sobre a influência das referidas estratégias de amostragem nos resultados da classificação pelo método Gaussiano da Máxima Verossimilhança não verificou diferença significativa ao nível de confiança de 90%, segundo Gonçalves *et al.* (2007b). Uma vez definida a estratégia de amostragem, deve-se verificar o número de amostras necessárias, bem como a quantidade ideal de pixels nessas amostras. A opinião de Gruijter (1999) é que o número ideal de amostras depende da variabilidade espacial da área e do número de classes, entretanto, são recomendadas pelo menos de 5 a 10 amostras por classe. Além do número de amostras, de acordo com Mather (2004) a validade das estimativas estatísticas depende do número de variáveis discriminantes (bandas espectrais) que serão base para estimação dos parâmetros estatísticos e da representatividade da amostra. Para amostragem utilizou-se polígonos de referência coletados com acompanhamento de profissionais da Secretaria Municipal Adjunta de Meio Ambiente (SMAMA). Para o caso de algoritmos de classificação estatísticos, Mather (2004) sugere a seguinte fórmula empírica para determinar o número mínimo de pixels de amostra por classe informacional:

$$Np = 30 * NVD * Ncl \quad (3)$$

em que Np é o número total de pixels, NVD o número de variáveis discriminantes e Ncl o número de classes informacionais.

Quanto à avaliação das imagens temáticas geradas, o método mais comum para representar a exatidão da classificação é através da construção de uma matriz de erro, que fornece elementos para obter o coeficiente *Kappa*, comumente empregado para avaliar a qualidade da classificação (MATHER, 2004). Na opinião de Congalton (1991) este coeficiente é uma medida apropriada para medir a exatidão de uma classificação temática, porque contempla toda a matriz de erros. Skidmore (1999) apresenta as equações para obter o coeficiente *Kappa* e sua variância. O coeficiente *Kappa* é obtido pela fórmula:

$$\hat{\kappa} = \frac{\theta_1 - \theta_2}{1 - \theta_2} \quad (4)$$

onde:

$$\theta_1 = \sum_{i=1}^r \frac{x_{ii}}{n} \quad \text{e} \quad \theta_2 = \sum_{i=1}^r \frac{x_{i+} x_{+i}}{n^2}$$

Na expressão, x_{i+} é a soma da i ésima linha, x_{+i} a soma da i ésima coluna e x_{ii} representa a contagem dos valores na linha e coluna i , ou seja, a diagonal da matriz de erros que, por ser quadrada tem r linhas e colunas e um total de n elementos.

A variância do coeficiente *Kappa* pode ser obtida por:

$$\hat{\sigma}_{\hat{\kappa}}^2 = \frac{1}{2} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4} \right] \quad (5)$$

em que

$$\theta_3 = \sum_{i=1}^r \frac{x_{ii}(x_{i+} + x_{+i})}{n^2} \quad \text{e} \quad \theta_4 = \sum_{i,j=1}^r \frac{x_{ij}(x_{i+} + x_{+i})^2}{n^3}$$

e x_{ij} trata-se do valor de intersecção entre a i ésima linha e a j ésima coluna.

Em seu trabalho, Vieira (2000) emprega o teste estatístico Z como alternativa para determinar diferença significativa entre valores independentes de coeficiente *Kappa*, o que permite comparação estatística entre dois métodos ou algoritmos de classificação diferentes. Desse modo, duas hipóteses são testadas estatisticamente. Ao nível de significância de 0,05%, pelo teste estatístico Z bilateral, dada hipótese de nulidade para coeficientes *Kappa* equivalentes ($H_0 : \hat{\kappa}_1 = \hat{\kappa}_2$), e hipótese alternativa para coeficientes

Kappa diferentes ($H_1 : \hat{\kappa}_1 \neq \hat{\kappa}_2$), H_0 deve ser rejeitada se $Z > 1,96$. A determinação da distribuição normal de valores Z é obtida pela razão entre o valor de diferença de dois coeficientes *Kappa* distintos e o valor da diferença de suas respectivas variâncias, pela fórmula:

$$Z = \frac{\hat{\kappa}_1 - \hat{\kappa}_2}{\sqrt{\hat{\sigma}_{\hat{\kappa}_1}^2 - \hat{\sigma}_{\hat{\kappa}_2}^2}} \quad (6)$$

2.5 O contexto e o conhecimento especialista.

O termo contexto empregado no sensoriamento remoto tem sido discutido com o sentido de vizinhança espacial do pixel. Vieira (2000) descreve o contexto em três dimensões, a espectral (as diversas bandas do espectro eletromagnético), a espacial (em termos da correlação espacial do pixel com sua vizinhança imediata adjacente) e a temporal (em referência às múltiplas imagens de uma mesma área). Benz *et al.* (2004) apontam para dois tipos de informação contextual, a global – que descreve a situação da imagem (tempo e sensor) e a local – que descreve relações das regiões da imagem (correlações espaciais dos pixels). Exploram a ligação entre SIG e SR através da análise *fuzzy*³ orientada a objeto, considerando informação contextual de múltiplas fontes. Exemplos no sentido de contexto espacial podem ser objetivamente encontrados em Stuckens *et al.* (2000), De Jong *et al.* (2001), Pellizzeri *et al.* (2003), Benz *et al.* (2004), Mather (2004), Laha *et al.* (2006), Melgani (2006), Melgani e Bazi (2006), nos quais os autores empregam o contexto aplicado nas mais diversas situações. Logo, o conceito de informações contextuais pode assumir uma semântica distinta a depender da referência na qual essa aplicação é apoiada.

O termo conhecimento freqüentemente é encontrado com conotações diversas, hora num sentido restrito relacionado aos dados, incluindo contexto, modelos e regras, hora com significado mais amplo, para descrever algum tipo de informação externa aos dados trabalhados. Baltsavias (2004) menciona alguns aspectos relativos ao conhecimento que devem ser considerados, tais como: tipos de conhecimento; problemas em se empregar conhecimento; representação e gerenciamento do

³ *Fuzzy* é uma generalização da lógica booleana que admite valores intermediários entre o falso e o verdadeiro (exemplo: talvez). Consiste de uma família de modelos matemáticos para tratar incertezas.

conhecimento; uso atual e possível do conhecimento; e exploração, atualização e aquisição do conhecimento. Ao abordar representação e gerenciamento do conhecimento, menciona que por vezes utilizam-se os termos conhecimento, contexto e domínio de maneira vaga, em cada caso com um significado diferente; redes de credibilidade (*Belief nets*) são abordadas como sinônimas de redes Bayesianas (*Bayesian nets*) ou na contextura da Teoria de Evidências *Dempster-Shafer*⁴, causando certa confusão ao leitor. O conceito de domínio está relacionado à como os objetos são na realidade, suas características de forma, tamanho e constituição, por exemplo. Essa relação conceitual de domínio implica em uma grande dificuldade de empregá-lo com segurança no processo de modelagem.

Stuckens *et al.* (2000) utilizam um procedimento de segmentação por crescimento de regiões, iterativo, para integrar informação contextual com a classificação por pixel. Uma dificuldade do método pode ser atribuída à interpretação visual para atestar o critério de aceitação (distância euclidiana até o vetor de média da região) do pixel à região e à inspeção visual da imagem de saída até que iterativamente fosse obtida convergência. Em contrapartida, a avaliação da classificação com emprego do método exibe melhores resultados do índice de exatidão *Kappa*. Adicionalmente, o método proporciona um mapa temático final mais atrativo visualmente devido aos limiares de área minimamente mapeáveis adotados no procedimento. Os autores De Jong *et al.* (2001) utilizam a integração espacial-espectral de informações diretamente na classificação de cobertura vegetal. Perfis espectrais definem áreas homogêneas que são utilizadas para classificar pixels heterogêneos, com ganho de resultados. O tema Informações Contextuais⁵ é explorado por Vieira (2000) e Mather (2004) como técnicas de pós-classificação (refinamento), considerando o produto gerado (imagem temática) e sugerem técnicas (entre outras, filtro da moda, função de proximidade e métodos

⁴ Conforme Press (1989), em 1967 Dempster desenvolveu um novo sistema axiomático de probabilidades baseados em “a menor e a maior probabilidade” usando transformação multivalorada para conjuntos de eventos, com uma regra de não-adição para combinação de probabilidades. Press (1989) menciona ainda que pouco depois, em 1976, usando o modelo de Dempster, Shafer produziu um novo sistema de probabilidade baseado em funções de “credibilidade”.

⁵ Para os autores tais informações são consideradas sob duas abordagens. A abordagem por objeto considera as características espectrais de um determinado pixel independente (vetor espectral) para associá-lo a uma categoria em particular. Apesar de se tratar de um método eficiente e rápido é mais susceptível a produzir ruídos, pois cada pixel representa um vetor espectral distinto. Desconsideram a influência da informação da vizinhança espacial do pixel para associá-lo a uma classe específica. A abordagem por região considera todo um agrupamento de pixels espectralmente semelhantes como unidade significativa. Técnicas de segmentação são utilizadas para definir as fronteiras do agrupamento de pixels. Resultados obtidos com a avaliação dos produtos obtidos através da abordagem por região são consideravelmente melhores daqueles obtidos com a abordagem por objeto, no entanto, seu custo computacional de implantação é oneroso (em relação à abordagem por objeto). Maiores detalhes sobre a representação por objeto ou por região podem ser verificados em Vieira (2000).

geoestatísticos para caracterizar o contexto espacial do pixel) para suavização ou melhoria da exatidão da classificação. Outro grupo de pesquisadores (PELLIZZERI *et al.*, 2003) utilizou imagens de radar (*Synthetic Aperture Radar - SAR*) para classificação de áreas urbanas confrontando as abordagens: estatística e *fuzzy*. Usaram informação contextual espacial para aumentar a capacidade de discriminação entre regiões adjacentes aplicadas às duas abordagens e concluíram que ambas são capazes de explorar as características espaciais juntamente com as espectrais, contribuindo para melhor desempenho da classificação. Há estudos que contribuíram para o desenvolvimento de um elaborado esquema para projeto de um classificador contextual utilizando imagens multiespectrais através de fundamentos da lógica *fuzzy*. Nesses estudos, os autores (LAHA *et al.*, 2006) mencionam que a disponibilidade de determinado esquema depende da natureza dos dados e o desempenho individual de cada esquema deve ser avaliado através de treinamento e teste para escolha do melhor. Informações contextuais são exploradas para detecção não-supervisionada de mudanças, através da técnica *Markovian Random Field - MRF* que, segundo os autores Melgani e Bazi (2006), é capaz de perceber as melhores peculiaridades de diferentes algoritmos e explora características espaciais de uma forma natural. Outro trabalho interessante desenvolvido por Melgani (2006) explora a reconstrução contextual de uma imagem contaminada por nuvens a partir de uma série multitemporal e multiespectral de imagens. Nesse trabalho, o autor realiza predição contextual linear através da distribuição estatística condicionada ao tipo de cobertura e não linear através de uma técnica que objetiva encontrar uma função que suavize e reduza o maior desvio a partir dos alvos. Apesar da complexidade do problema, Melgani (2006) conclui que foi possível obter bons resultados na remoção das nuvens com a abordagem proposta.

Ante ao exposto, faz-se necessária uma explicação com vistas a esclarecer o motivo de o termo contexto ter sido usado com outra conotação (não espacial) durante o texto. Na língua portuguesa o termo “contexto” exprime sentido um tanto menos apropriado que o sentido dado quando traduzido pela língua inglesa (considerado sua aplicação em referência a espaço). Uma simples consulta ao dicionário revela a primeira definição para o termo contexto como: “inter-relação de circunstâncias que acompanham um fato ou uma situação” (HOUAISS, 2001). Logo, cabe esclarecer que o real motivo dessa opção não se expressa por simples rebeldia ou desacordo com as idéias centrais de contexto consolidadamente exploradas pelos maiores especialistas, mas sim por uma questão de preocupação por uma maior adequação do tema à Língua Portuguesa. Entende-se que o termo contexto, tal como é definido na Língua

Portuguesa, pode sim ser melhor abordado (colocado) no sensoriamento remoto, conforme é evidenciado durante o desenvolvimento das idéias apresentadas neste trabalho. Mais especificamente, entenda-se contexto como a ocorrência de determinadas circunstâncias (naturais ou não) dotadas do atributo de localização espacial, que exibem padrões de inter-relação que por sua vez condicionam a ocorrência de um evento (ou situação) específico.

A relação que informação e fenômeno ocorrem em associação se verifica através do contexto de contribuição condicional da informação para o fenômeno, ou seja, determinado fenômeno passa a ser observado em conjunto com as informações (nesse sentido, variáveis) que o condicionam, em oposição a observá-lo de modo independente. O conhecimento especialista aplicado a metodologias de classificação é amplamente explorado na literatura, como pode ser verificado em vários trabalhos, a exemplo dos de Fritz e See (2005), Chanussot *et al.* (2006), Cayuela *et al.* (2006), Daniels (2006) e Domaç e Süzen (2006). Com o objetivo de comparar mapas de uma mesma área, porém com diferentes categorias, Fritz e See (2005) empregaram conhecimento especialista e lógica *fuzzy* para mapear as coincidências. O conhecimento especialista é abordado com significativo detalhe, onde consideraram opiniões de vários especialistas sobre as incertezas das classes de vegetação ocorridas na classificação. Em trabalho realizado para fins de classificação urbana, Chanussot *et al.* (2006) usaram o conhecimento especialista para prover informações sobre tamanho e contraste de objetos no meio urbano, com posterior união dessas informações e introdução ao modelo de possibilidades *fuzzy*. Destacam ainda que foi possível modelar o conhecimento do especialista sobre os parâmetros (tamanho e contraste) de objetos da superfície em distribuições de possibilidades e atestam que o modelo obtido apresenta algumas vantagens de flexibilidade e simplicidade.

Dentre os trabalhos mencionados, cabe ressaltar que os desenvolvidos por Domaç e Süzen (2006), Cayuela *et al.* (2006) e Daniels (2006) foram importantes fontes de referência para o desenvolvimento do presente trabalho. Cayuela *et al.* (2006) destinaram-se à classificação de uma complexa cobertura do solo empregando a teoria de evidências *Dempster-Shafer*. Para isso, introduziram a informação espectral das imagens na forma de probabilidades Bayesianas baseadas na Matriz de Variância Covariância (MVC) das amostras de treinamento, que produziram imagens fundamentadas em probabilidades atualizadas para cada classe. Foram geradas também imagens fundamentadas em probabilidades baseadas no conhecimento de especialistas

regionais sobre a ocorrência das diferentes coberturas do solo condicionadas a fenômenos da paisagem, como altitude, declividade, entre outros. Os resultados obtidos com o método apontam para uma redução do erro de omissão e comissão para cada classe, além de redução do erro total da classificação de aproximadamente 7,5%. Concluem que a distinção do gradiente de transição da vegetação natural apenas através da informação espectral é difícil e que o procedimento adotado oferece vantagem em relação aos procedimentos convencionais. Daniels (2006) argumenta que a classificação baseada apenas na informação multiespectral emprega uma mera fração dos critérios discriminatórios relevantes para produção de mapas de cobertura do solo. Por isso, sugere incorporar informações externas (variáveis de ambiente como índice de vegetação, altitude, declividade, entre outras) e conhecimento especialista, para que apenas as informações mais adequadas à determinação de uma classe específica sejam consideradas. Relata que, ao comparar os resultados de sua metodologia, que contempla o conhecimento como o método de classificação Gaussiano da Máxima Verossimilhança, esses foram melhores em todos os casos. Conclui que sua metodologia permite uma classificação mais exata e é aplicável a vários tipos de cobertura do solo.

Para finalizar, uma extensa revisão a respeito da análise de imagens empregando dados existentes e conhecimento especialista pode ser verificada em Baltsavias (2004). Menciona, por exemplo, uma série de métodos para representação do conhecimento como Redes Neurais Artificiais, Linguagens de Programação em Lógica, Sistemas Especialistas, Lógica Nebulosa e Conjuntos Nebulosos, Redes Bayesianas e Teoria da Probabilidade, Teoria de Evidências *Dempster-Shafer*, entre outras.

2.6 Informações contextuais.

Considerada toda sorte de variáveis influentes na composição da imagem e no processo de classificação, intercede-se a favor da inclusão de outro tipo de informação, além da espectral, para caracterizar com maior rigor os diferentes tipos de cobertura do solo. Apesar da impossibilidade de conhecer ou mesmo modelar matematicamente todas as variáveis causais, algumas são condicionadas a circunstâncias específicas que restringem sua efetiva ocorrência e, entre essas, há as que são possíveis de serem

modeladas. Quem detém o conhecimento de causa a esse respeito é geralmente o especialista, que há tempo dedica-se ao estudo do assunto apontado. Entretanto, ao conduzir um processo de classificação, esse especialista por vezes se vê obrigado a contar apenas com métodos de classificação tradicionais e modelos que oferecem pouca ou nenhuma liberdade para introduzir seu conhecimento no processo. Isto se deve, em parte, à dificuldade de acesso aos meios de divulgação de vanguarda que prezam por métodos inovadores, ou ainda, à complexidade desses últimos, quando acessíveis.

A idéia central desenvolvida neste trabalho preza pela inclusão de informação contextual (além da espectral) em forma de conhecimento especialista, modelado com menor empirismo e maior fundamento estatístico e ainda de maneira simples, no processo de classificação de imagens. São propostas duas maneiras de inclusão do conhecimento, de forma direta ou indireta (por modelagem). Pela forma direta, a informação é incluída sem necessidade prévia de tratamento. Pela indireta, utiliza-se a Inferência Bayesiana como ferramenta.

Para a modelagem indireta, pode-se considerar o uso de Modelo Digital de Elevação (MDE) para melhorar o desempenho da classificação de imagens, pois tem sido amplamente explorado, e apresentado bons resultados. Eiumnoh e Shrestha (1997) usaram o MDE juntamente com adição dos dados mutiespectrais e observaram melhora significativa dos resultados ao comparar com procedimento convencional de classificação de imagens. Além disso, o MDE oferece também a possibilidade de derivar outros modelos topográficos que podem ser empregados com o mesmo objetivo, ampliando oportunidades de análise como em Domaç e Süzen (2006).

Desse modo, as informações contextuais podem ser pensadas como variáveis de ambiente: topográficas e espectrais. Para este trabalho, variáveis de ambiente topográficas são as geradas a partir do Modelo Digital de Elevação Hidrologicamente Consistente (MDEHC) e as variáveis de ambiente espectrais podem ser os índices espectrais obtidos por operações entre bandas. O Índice de Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index – NDVI*) é um exemplo de variável espectral. O NDVI é obtido por operação aritmética de razão entre diferença e adição das bandas do infravermelho próximo e vermelho, pela fórmula:

$$NDVI = \frac{NIR - R}{NIR + R} \quad (7)$$

em que *NIR* é a REM na banda da região espectral do infravermelho próximo e *R* a REM na banda da região do vermelho. O NDVI oferece boa distinção entre materiais

como vegetação, solo e água. Variáveis topográficas comuns, derivadas do MDEHC são a Declividade, com valores expressos em percentagem ou graus e o Azimute da face de maior inclinação, com valores expressos em graus. O valor de declividade de um pixel (central) é calculado como resultante do vetor de inclinação determinado a partir do valor dos pixels vizinhos imediatos: superior, inferior, da esquerda e da direita (EASTMAN, 2006). Seu valor representa a tangente do ângulo com maior inclinação de declividade. No entanto, os valores de Azimute da face de maior declividade podem causar confusão em uma análise estatística, devido sua característica circular de representação, isto é, valores de 2° e 358° são muito semelhantes em campo, no cenário real. Para solucionar a questão, um método apontado por Domaç e Süzen (2006, p.1337) sugere a transformação trigonométrica dos valores de Azimute da face de maior declividade em seus componentes, produzindo novas variáveis chamadas “*Northness*” e “*Eastness*”. Essas representam as faces Norte-Sul e Leste-Oeste, determinadas respectivamente por operações de Cosseno e Seno aplicadas aos valores de Azimute da face de maior declividade. A face do terreno está diretamente relacionada à incidência de radiação solar recebida pela superfície durante o dia, por isso, acredita-se estarem relacionadas ao desenvolvimento vegetativo. Em conjunto, todas essas variáveis topográficas foram também utilizadas com sucesso no trabalho de Domaç e Süzen (2006) para propósitos de classificação de espécies florestais a partir de imagens.

2.7 O Paradigma Bayesiano.

Antes de abordar efetivamente as idéias gerais sobre o paradigma Bayesiano, vale mencionar que seu estudo iniciou (e até hoje é intrinsecamente relacionado) nas escolas de psicologia em conjunto com as de matemática, com *status* de forma de pensamento. Em seqüência tem-se uma breve introdução sobre Thomas Bayes⁶. Após, discute-se o paradigma clássico e o Bayesiano, comentando as diferenças principais dessas duas escolas para então introduzir o raciocínio Bayesiano. Por fim, são comentadas

⁶ A maior parte da informação utilizada para produção deste tópico foi retirada de um artigo da Revista Ciência Hoje (PENA, 2006) e dos apêndices (1, 2, 3 e 4) da obra de Press (1989). No primeiro apêndice, Hilary L. Seal trata episódios em torno do manuscrito de Bayes e sua notável semelhança com o trabalho de Laplace. No segundo, G. A. Bernard traz algumas notas bibliográficas sobre Thomas Bayes, apontando inclusive para a dificuldade de se encontrar material a respeito de sua história. No terceiro apêndice é apresentado o prefácio feito por Richard Price (amigo de Bayes que divulgou sua obra postumamente). O quarto apêndice trata-se de uma reprodução do próprio manuscrito.

aplicações do paradigma Bayesiano para estudos de caso aplicados ao sensoriamento remoto.

2.7.1 Um pouco sobre Thomas Bayes.

Filho mais velho do Reverendo Joshua Bayes e Ann Bayes, Thomas Bayes foi um Ministro Presbiteriano e matemático que viveu na Inglaterra no início do século XVIII (nasceu em 1702 e faleceu em 1761). Estudou teologia na Universidade de Edimburgo (Escócia) até 1722; em 1731 assumiu a paróquia de *Tunbridge Wells* no condado de *Kent*, a 58 km de Londres (PENA, 2006). Em vida, publicou dois tratados em metafísica (em 1731⁷ e em 1736⁸) e provavelmente devido a eles foi eleito membro da Sociedade Real em 1742. Sua única contribuição matemática foi a publicação póstuma de dois artigos em 1764, pelo seu amigo e interessado em suas pesquisas Richard Price (nasceu em 1723 e faleceu em 1791). O primeiro artigo praticamente não teve repercussão, foi escrito em poucas palavras e em forma de carta e sem data. Já o segundo artigo publicado, submetido ao *Philosophical Transactions of the Royal Society*, tratava-se do famoso manuscrito em probabilidade inversa para distribuição binomial, cujo título original é: *An Essay towards Solving a Problem in the Doctrine of Chances – Um Ensaio Buscando Resolver um Problema na Doutrina das Possibilidades*. Na época, Bayes restringe seu teorema apenas ao caso da distribuição binomial. O problema postulado no seu ensaio foi: “*Dado o número de vezes nas quais um evento desconhecido aconteceu e falhou: requisitada a possibilidade de que probabilidade de seu acontecimento numa única tentativa permaneça em algum lugar entre dois graus de probabilidade possa ser especificada*”. Seu ensaio é fundamentado em 10 suposições definidas em termos de eventos independentes mutuamente exclusivos, ditos determinados quando acontecem ou falham, de forma que sua probabilidade seja dada pela razão entre o valor que uma expectativa dependente do acontecimento do evento seja computada e o valor da possibilidade esperada sobre seu acontecimento. Neste ponto Bayes esclarece: “*por possibilidade quero dizer o mesmo que probabilidade.*” E finaliza a definição esclarecendo que um evento é independente quando seu

⁷ Artigo publicado sob o título: *Divine Benevolence, or an attempt to prove that the Principal End of the Divine Providence and Government is the happiness of His Creatures.*

⁸ Obra publicada sob o título: *An Introduction to the Doctrine of Fluxions, and a Defense of the Mathematicians against the objections of the Author of the Analyst.*

acontecimento não aumenta ou reduz a probabilidade de outros eventos. Para ter acesso ao ensaio (BAYES, 1764) na íntegra, pode-se consultar o Apêndice 4 do livro de Press (1989) ou em vários locais na Internet (por exemplo, no sítio do departamento de estatística da *University of California - UCLA*).

A controvérsia em torno do trabalho de Thomas Bayes se deve principalmente por opiniões confrontantes de adeptos e não adeptos do trabalho ter sido atribuído a ele. Têm sido levantadas questões acerca de quem na verdade escreveu o artigo atribuído a ele (PRESS, 1989), já que seu amigo Richard Price escreveu o prefácio, as notas de rodapé e o apêndice da obra. Há dúvidas sobre do que realmente trata seu teorema, uma vez que a teoria de probabilidade que precede a Suposição 9 no ensaio é “*excessivamente obscura*”, nas palavras de Press (1989). Outro fato instigante em torno do trabalho questiona o porque de não ter sido publicado em vida (LEE, 1997). Em contrapartida, há os autores (PRESS, 1989) que elegem o ensaio de Bayes como uma obra prima de elegância matemática, alguns consideram o trabalho como sendo da maior qualidade. Press (1989) menciona que as contribuições matemáticas de Bayes o colocam no primeiro time de pensadores independentes.

Segundo Press (1989), foi provavelmente Pierre Simon Laplace, em 1774, quem especificou a forma geral do teorema da probabilidade inversa independente, sem sequer ter visto o ensaio de Bayes. Laplace conduziu seu trabalho na França enquanto Bayes na Inglaterra, onde seu trabalho foi praticamente esquecido por quase 20 anos. Bayes (baseado na Suposição 1) e Laplace chegaram a uma opinião comum sobre as probabilidades *a priori*. No ensaio postulado de Bayes: “...*todos os valores de probabilidade desconhecida são igualmente apropriados antes de serem feitas observações.*” Segundo Press (1989), no seu primeiro artigo, publicado em 1774, Laplace (sem mencionar Bayes) introduziu o princípio que se a probabilidade de um evento observável é resultante de uma causa, então a causa operou para produzir o evento, e isto implica que a probabilidade inicial das causas deve ser a mesma. Dessa idéia surgiu o Princípio da Razão Insuficiente de Bayes-Laplace (PAULINO *et al.*, 2003; PRESS, 1989), atestando que na ausência de qualquer razão em contrário, todos os valores do parâmetro desconhecido devem ser iguais. Conforme Press (1989), em 1814, anos depois de sua primeira publicação, Laplace publicou outro artigo dizendo que as causas não são igualmente prováveis. Além disso, James Bernoulli⁹ pode ter

⁹ Thomas Bayes foi educado em casa, tendo aulas particulares. Especula-se que por volta dos 12 anos pudesse ter tido aulas de matemática com Bernoulli (um dos fundadores da teoria da probabilidade – definindo-a como grau de confiança numa dada proposição que não se sabe se é verdadeira ou falsa), que

provavelmente concebido antes, em 1713, no seu tratado em probabilidade chamado *Ars Conjectandi* (publicado postumamente), as idéias atribuídas a Thomas Bayes (PAULINO *et al.*, 2003). Neste trabalho, apesar de não ter dado uma estruturação matemática apropriada, o autor desenvolveu o teorema binomial, deixou as regras para permutações e combinações e postulou o problema da probabilidade inversa (PRESS, 1989).

Controvérsias a parte, o fato é que o trabalho ficou mesmo conhecido como Teorema de Bayes, ou seja, foi a ele atribuído e, deixando de lado essa questão polêmica, o que realmente importa é a idéia central apresentada pelo teorema e este é o lugar onde devem ser concentrados esforços na exploração de novas técnicas e outras possíveis aplicações. Aos interessados na polêmica, muito ainda pode ser especulado sobre a questão da paternidade do Teorema de Bayes ou mesmo sobre a figura do próprio Thomas Bayes, de modo que a questão se encontra ainda longe de um argumento conclusivo contundente.

2.7.20 raciocínio Bayesiano.

Para entender propriamente o pensamento Bayesiano, comenta-se as diferenças principais entre as duas escolas do pensamento estatístico: a clássica (frequentista), fundada por Karl Pearson, Ronald Fisher e Jerzy Neyman, e a Bayesiana. Um dos principais motivos está na objetividade contra subjetividade. A intenção geral da estatística clássica é determinar que generalizações sobre uma população possam ser feitas a partir de amostras dessa população (PAULINO *et al.*, 2003). Conforme menciona Press (1989), alguns pesquisadores e estatísticos dizem que a ciência deve ser mais objetiva quanto possível e seus cálculos devem ser livres de sentimentos e crenças pessoais, portanto rejeitam metodologias que consideram o subjetivismo. Paulino *et al.* (2003) diz que *“a diferença fundamental é que Bayesianos (entre outros) introduzem novos princípios (filosóficos) de inferência... A inferência clássica, agarrada à interpretação empirista das probabilidades, procura apenas critérios mais ajustados, pois não perde o sentido do real. Nas outras inferências a escolha é a gosto, num largo*

na época escreveu a Leibniz dizendo que tinha que ganhar a vida em Londres ensinando matemática (PRESS, 1989; PAULINO *et al.*, 2003).

leque de princípios, mas o real escapa-se.” A esse argumento, Press (1989) coloca um contra-argumento, dizendo que a ciência foi e ainda é subjetiva, pois quando o Pesquisador resolve conduzir um experimento em particular, o motivo freqüente é porque ele preconcebeu noções¹⁰ sobre o que gostaria de encontrar, então, conduz o experimento que pode ser confirmatório (pode confirmar ou rejeitar a hipótese assumida) ou exploratório (nesses casos, o pesquisador não apenas desconhece o que irá encontrar como também não tem sequer uma hipótese a respeito). No caso da condução de um experimento confirmatório, alguns dados pontuais são freqüentemente excluídos das análises por razões como: tratam-se de enganos; são valores grandes ou pequenos para serem considerados de interesse; as condições experimentais estavam diferentes das condições de observação (ou seja, razões um tanto subjetivas). Por fim, para testar a hipótese, o pesquisador define subjetivamente um nível de significância para sua rejeição. Paulino *et al.* (2003) em relação ao paradigma freqüentista tem a seguinte posição: *“Os métodos tradicionais que usam apenas distribuições de amostragem são usáveis e úteis em vários problemas particularmente simples e idealizados; mas eles representam os casos especiais mais proscritos da teoria da probabilidade, porque eles pressupõem condições que são dificilmente encontradas em problemas reais. Esta abordagem é um tanto inadequada para as necessidades atuais da ciência.”* Apesar das diferenças cabe esclarecer que não há controvérsias sobre o Teorema de Bayes e ele é usualmente adotado por Bayesianos e não Bayesianos. Na opinião de Lee (1997), a característica que diferencia a Estatística Bayesiana é a aplicação do teorema em circunstâncias que não são usualmente admitidas pelos classicistas. Afirma ainda que Bayesianos falam indistintamente sobre probabilidades de hipótese *a priori* e *a posteriori*, enquanto os outros falam apenas da probabilidade de hipótese em circunstâncias restritas. Idéias relativas a níveis de significância, intervalos de confiança e probabilidades fiduciais, que tentam satisfazer a necessidade de saber quão certo se está após observar os dados, enquanto proscvem a idéia de quão certo se estava antes, são deficientes segundo Edwards *et al.* (1995).

O raciocínio Bayesiano, através da Estatística Bayesiana, estabelece que um determinado parâmetro possua uma distribuição *a priori* e esta representa o grau de convicção pessoal acerca do parâmetro, mesmo antes de se observar o conjunto de dados ou mesmo conduzir qualquer experimento com eles, definindo probabilidade

¹⁰ São as hipóteses no formalismo do método científico.

como medida particular de opiniões de pessoas coerentes¹¹. O Teorema de Bayes fornece um procedimento matemático para atualizar o grau de convicção *a priori* acerca do valor de um parâmetro desconhecido fornecendo uma distribuição *a posteriori* para o mesmo à luz de nova informação ou evidência. Especifica como deve ser feita essa atualização de opiniões pela Inferência Estatística (EDWARDS *et al.*, 1995; PRESS, 1989). Desse modo, pode-se enxergar a Inferência Bayesiana como o uso da probabilidade para medir opiniões coerentes, as quais são atualizadas a partir de informações novas conforme o Teorema de Bayes estabelece.

No entanto, há diversas questões envolvidas no significado preciso de probabilidade pessoal e grau de convicção implicado neste paradigma (POLSON e TIAO, 1995). No artigo de Ramsey (1995), o autor desenvolve argumentos a respeito de grau de convicção em profundidade. Começa dizendo que as pessoas comuns usam inadvertidamente os termos probabilidade e proporção como sinônimos, acrescenta que probabilidades e graus de convicção são naturalmente expressos em termos numéricos, entretanto, não há correspondência direta entre suas relações. A partir de uma seqüência lógica e bem organizada de raciocínio, Ramsey (1995) conduz a uma estruturação matemática para determinar a consistência do grau de convicção do indivíduo, que distingue conjuntos de convicção respeitando certos preceitos de consistência (maiores detalhes em Ramsey (1995)). Probabilidade pessoal é tema amplamente discutido por Edwards *et al.* (1995) e, posteriormente, por Savage (1995), para fins de aplicação em Economia, onde ganha estruturação matemática.

O problema das probabilidades *a priori* é observado quando essas são vagas e variáveis (indesejada para fins científicos), ditas não-informativas. Entretanto, pode ter efeito negligente na distribuição *a posteriori*, a depender do volume de dados disponível. Como o Teorema de Bayes produz uma revisão de opiniões com base em evidências, um maior número dessas pode causar redução no papel desempenhado pela distribuição *a priori*. Isto implica que, nas situações onde o volume de dados é pouco, o modelo probabilístico desempenha o papel essencial para os resultados, pois os dados são fortemente influenciados pelo modelo. Contudo, em situações onde o volume de dados é grande, o modelo probabilístico reduz seu papel e os dados têm maior influência. Segundo Edwards *et al.* (1995), freqüentemente os dados controlam tão

¹¹ Pode-se entender por pessoa coerente um indivíduo que emita opinião fundamentada no Princípio da Coerência, que se baseia em: (i) todo indivíduo frente a um acontecimento incerto tem atitude que pode ser medida em termos de probabilidade; (ii) as probabilidades referentes a esse indivíduo específico podem ser comparadas; (iii) essas probabilidades podem ser avaliadas em termos de coerência, verificando sua contradição para determinada situação hipotética. Veja detalhes em Edwards *et al.* (1995).

fortemente a distribuição *a posteriori* que praticamente não há necessidade de atentar para detalhes da distribuição *a priori*. As distribuições *a priori* são usualmente categorizadas em próprias ou impróprias. São ditas próprias quando não dependem dos dados e sua integral é 1. Situações de distribuições *a priori* impróprias que conduzem à distribuições *a posteriori* próprias devem ser vistas com muita cautela e interpretadas como aproximações em que os dados observados são mais importantes, fazendo com que a verossimilhança domine a distribuição *a priori* (GELMAN *et al.*, 1995).

Expor apropriadamente e com a devida importância todo arcabouço conceitual que envolve as distribuições *a priori* na Inferência Bayesiana foge ao escopo deste trabalho. Logo, apenas os detalhes específicos para aplicação do método são discutidos (maiores detalhes sobre distribuições *a priori* podem ser consultados em Gelman *et al.*, (1995) e Savage (1995)).

2.7.3 Aplicações do paradigma Bayesiano ao sensoriamento remoto.

Há várias possibilidades de aplicação do paradigma Bayesiano ao SR e muitas dessas são direcionadas exclusivamente para propósitos de melhoria dos resultados dos processos classificação de imagens, tais como, integração de dados (MELGANI e SERPICO, 2002; MALPICA *et al.*, 2007); classificação de imagens por Redes Bayesianas (PINZ *et al.*, 1996; MELLO *et al.*, 2007); análises multitemporais para mapeamento da cobertura terrestre (ZHU e TATEISHI, 2006); introdução de conhecimento especialista (ABKAR *et al.*, 2000), entre outros. No entanto, nota-se que muito pouco dessas possibilidades de aplicação foi explorado.

Resultados de estudos realizados na tentativa de integrar dados de informações espaciais, temporais, contextuais e espectrais para classificação de imagens, empregando o paradigma Bayesiano (*Bayes rule for Minimum Error – BRME*), mostraram ser uma abordagem atrativa em termos de simplicidade de aplicação em comparação a outros métodos analisados (MELGANI e SERPICO, 2002). Malpica *et al.* (2007) realizaram trabalho para classificação em SIG utilizando sofisticadas metodologias (como redes neurais artificiais, teoria de evidências e paradigma Bayesiano) para obter fusão com dados do sensoriamento remoto e concluíram que as metodologias são complementares entre si, em oposição a se destacarem uma das

outras, ou seja, algumas são mais adequadas em situações específicas, mas não em casos gerais. Redes Bayesianas, dentre outras metodologias, são empregadas por Pinz *et al.* (1996) para classificação com imagens multitemporais e multiespectrais explorando técnica de fusão ativa¹². Nesse trabalho consideraram um conjunto de hipóteses formuladas como variáveis aleatórias (discretas ou contínuas), associadas a uma distribuição de probabilidades específica que define a incerteza do sistema em relação ao valor verdadeiro das hipóteses. Essa incerteza inerente é que fornece o controle de adição de dados e o critério de parada. Concluem que a seleção da fonte de dados estritamente mais informativa reduz os recursos que devem ser ativados, com resultados robustos e confiáveis (PINZ *et al.*, 1996). Mello *et al.* (2007) empregaram Redes Bayesianas para identificação de culturas agrícolas utilizando informações externas para produzir uma máscara a partir de imagem de probabilidades gerada pela rede. Após, procederam com o processo de classificação pelo algoritmo Gaussiano da Máxima Verossimilhança aplicado às imagens com e sem a máscara. Compararam os resultados e verificaram que o uso da máscara proporcionou aumento substancial (de 0,84 para 0,94) do valor de índice *Kappa* de avaliação da classificação. Para abordagem multitemporal com fins de mapeamento da cobertura do solo, Zhu e Tateishi (2006) propõem uma metodologia para união de imagens de vários sensores e épocas através de formulação Bayesiana. Eles conseguiram melhores índices de avaliação da classificação tanto global quanto individualmente (para maioria das classes, especificamente 10 em 12 classes). A partir de experimentos, verificaram que os modelos de fusão propostos apresentaram sensibilidade à classificação de paisagens que sofreram modificação na cobertura, podendo ser empregados alternativamente em análise para detectar mudança de paisagem. Abkar *et al.* (2000) desenvolveram uma metodologia para segmentação de imagens na qual o critério de segmentação é derivado de verossimilhanças médias locais, ao contrário de médias ou variâncias locais, proporcionando menor sensibilidade a erros grosseiros decorrentes da radiometria. Utilizam a teoria de probabilidade Bayesiana para descrever as incertezas relacionais dos dados observados e o rótulo da classe, sendo os parâmetros do modelo obtidos por probabilidade combinada. A metodologia permite inserir conhecimento *a priori* da base de dados SIG na análise, pois sua fundamentação consiste na probabilidade combinada dos dados do SR e da classe-objeto.

¹² Além de prover a fusão de informação, a técnica fornece mecanismos para selecionar as fontes de informação a serem combinadas (PINZ *et al.*, 1996).

2.80 Teorema de Bayes.

O Teorema de Bayes trata da probabilidade condicional que, segundo Edwards *et al.* (1995), é a expressão probabilística de aprendizado pela experiência. Tal afirmação procede pelo fato da distribuição *a posteriori* ser a revisão da opinião, expressa pela distribuição *a priori*, aliada a combinação dos dados amostrais pela função de verossimilhança. Mais especificamente, segue-se o raciocínio: a probabilidade condicional $p(y|\theta)$ de um evento y dado um outro θ ocorre quando ambos são verdadeiros. Neste caso, trata-se da probabilidade de ocorrência conjunta dos dois eventos, expressa pela intersecção $p(y \cap \theta)$, dada por $p(y|\theta)p(\theta)$, conforme a forma:

$$p(y|\theta) = \frac{p(y \cap \theta)}{p(\theta)} \quad (8)$$

que é válido para valores de $p(\theta) \neq 0$. Como os eventos são conjuntos, logo são eventos em simetria, ou seja, y está para θ assim como θ está para y . O que equivale dizer:

$$\frac{p(y|\theta)}{p(y)} = \frac{p(y \cap \theta)}{p(y)p(\theta)} = \frac{p(y|\theta)}{p(\theta)}$$

para $p(\theta), p(y) \neq 0$. A simetria dos eventos garante então a forma fundamental do Teorema de Bayes equivalente a:

$$p(\theta|y) = \frac{p(y|\theta)p(\theta)}{p(y)} \quad (9)$$

onde $p(y) = \sum_{\theta} p(\theta)p(y|\theta)$ para valores de θ discretos ou $p(y) = \int p(\theta)p(y|\theta)d\theta$ para valores de θ contínuos, com $p(y) \neq 0$. A apresentação de $p(y)$ conforme a Equação (9) garante a permutabilidade de θ , representando probabilisticamente sua simetria na distribuição *a priori*. De acordo com Gelman *et al.* (1995), como $p(y)$ é independente de θ , pode ser considerado uma constante e por isso deve ser omitida de Equação (9), o que produz uma forma proporcional do Teorema de Bayes, como segue:

$$p(\theta|y) \propto p(\theta)p(y|\theta) \quad (10)$$

Pelo Teorema de Bayes (Equação (10)) nota-se que os dados y afetam a distribuição *a posteriori* $p(\theta|y)$ somente através da função $p(y|\theta)$, conhecida como função de verossimilhança, que representa a distribuição conjunta dos dados amostrais.

Função esta que obedece ao seguinte princípio: para um dado conjunto de dados, dois modelos probabilísticos quaisquer $p(y|\theta)$ que tem a mesma função de verossimilhança produzem a mesma inferência para θ , este é o princípio da verossimilhança (GELMAN *et al.*, 1995). Em outras palavras, o que se pretende obter com a abordagem Bayesiana é a distribuição *a posteriori* [$p(\theta|y)$] de um evento condicional qualquer. Para isso são utilizadas observações de informações que condicionam o evento, descritas por uma função de *verossimilhança* [$p(y|\theta)$] e também a opinião pessoal sobre parâmetros que interferem para o acontecimento do evento antes mesmo de observar sua realização, através de uma distribuição *a priori* [$p(\theta)$]. Ou seja:

$$posteriori \propto priori \times verossimilhança$$

Essa é a máxima central do pensamento Bayesiano.

Apesar da aparente subjetividade das distribuições *a priori*, os modelos Bayesianos apresentam intrinsecamente uma característica que permite tratá-las como objetivas e pode ser muito proveitosa para aplicações em análises de informações espaciais. Esta característica trata-se da teoria de grandes amostras ou teoria assintótica, que relaciona a distribuição *a posteriori* com o volume de dados de amostra disponível. Pela teoria, à medida que o tamanho da amostra aumenta, a influência da distribuição *a priori* na inferência diminui. A distribuição *a posteriori* passa a se comportar de acordo com os dados. Segundo Gelman *et al.* (1995) e Press (1989), isto implica que ao lidar com problemas que apresentem grande volume de dados de amostra pode-se reduzir a atenção em busca de uma formulação muito precisa para distribuição *a priori*, pois os dados da amostra irão desempenhar papel dominante na inferência. Lembrem, porém, que para casos em que ocorra o inverso, ou seja, o volume de dados de amostra seja menor, o papel da distribuição *a priori* passa a ser crítico na especificação do modelo. Felizmente, em aplicações do SR para análises espaciais, o volume de dados de amostras tende a ser freqüentemente numeroso.

2.9 Determinação do modelo probabilístico.

Obter um bom modelo de Inferência Bayesiana requer atenção na escolha de um modelo probabilístico adequado. Fatores como: características dos dados, objetivo da

inferência e espaço amostral devem ser observados. Para o caso postulado neste trabalho, o espaço amostral é cada pixel que compõe a imagem; o evento que se quer inferir é a probabilidade de ocorrência de uma classe informacional que se pretende determinar. As características dos dados revelam que para um único pixel, a probabilidade de ocorrência possível é de apenas uma classe de vegetação, eleita entre várias possíveis.

Como a probabilidade de cada pixel é diferente em toda imagem, seu valor não pode ser constante. Por outro lado, a opinião sobre cada classe informacional sobre o evento, é fixa para cada classe e, portanto, não pode ser variável. Tais características são de uma distribuição que considere y sucessos em n tentativas ou falhas, o que define uma distribuição Binomial em função dos parâmetros y e n , do tipo $\theta \sim Bin(n, y)$ para os dados. A forma geral da distribuição Binomial é então dada por:

$$p(y|\theta, n) \propto \theta^y (1-\theta)^{n-y} \quad (11)$$

em que y e n são inteiros positivos e θ uma probabilidade, portanto $\theta \in [0,1]$. Como a probabilidade do pixel é obtida através das variáveis de ambiente topográfico e variável de ambiente espectral, ou seja, os dados, logo a distribuição binomial trata-se da função de verossimilhança do modelo. De modo que os valores de probabilidade são variáveis para cada pixel da imagem.

Como a probabilidade pessoal de ocorrência do evento (certa classe informacional) é constante para cada evento, devido a uma questão de conveniência para determinar a distribuição *a priori*, optou-se pela escolha de uma distribuição conjugada à distribuição Binomial, ou seja, da mesma família. A alternativa foi uma distribuição Beta com parâmetros α e β , do tipo: $\theta \sim Beta(\alpha, \beta)$. A forma geral da distribuição Beta é dada por:

$$p(\theta|\alpha, \beta) \propto \theta^{\alpha-1} (1-\theta)^{\beta-1} \quad (12)$$

com valores de $\alpha, \beta > 0$ e constantes. Esses representam os parâmetros da família conjugada natural das distribuições Beta e Binomial pela equivalência de $\alpha-1$ sucessos *a priori* e $\beta-1$ falhas *a priori*. São parâmetros assumidos desconhecidos, chamados *hiperparâmetros*. É através deles que se pode inserir a *opinião pessoal* (ou probabilidade pessoal, como em Savage (1995)), acerca da distribuição, definindo sua forma por duas características como a média e a variância. Uma vez conhecidas a distribuição da amostra pela função de verossimilhança e a distribuição *a priori*

conjugada, pode-se empregar a Equação (10) para obter a função de distribuição *a posteriori*, que tem a forma:

$$p(\theta|\alpha, \beta, n, y) \propto \left[\theta^{\alpha-1} (1-\theta)^{\beta-1} \right] \left[\theta^y (1-\theta)^{n-y} \right] \\ \propto \theta^{y+\alpha-1} (1-\theta)^{n-y+\beta-1} \quad (13)$$

O modelo probabilístico *a posteriori* (Equação (13)) determinado através do produto da função de verossimilhança pela distribuição *a priori* atende às características dos dados (probabilidade variável) e é conveniente.

Uma vez estabelecido o modelo probabilístico *a posteriori* (Equação (13)), falta ainda lidar com determinação da probabilidade inicial (θ) para alimentar a equação. Para isso, deve-se pensar em uma estratégia capaz de manipular informações de dados contínuos (superfícies de terreno, variação espectral, entre outros) em regiões (locais na imagem) de ocorrência da classe informacional (evento), de modo a integrá-las e produzir como saída valores de probabilidade. Dentre os métodos capazes de tal resultado, pode-se citar a abordagem *fuzzy* num paradigma subjetivo, e a Regressão Logística Binomial (RLB) num paradigma estatístico. Como a Inferência Bayesiana já contempla a subjetividade, optou-se por utilizar a RLB no lugar da abordagem *fuzzy*.

A RLB como ferramenta estatística é capaz de descrever a relação entre uma ou mais variáveis independentes, de valores contínuos (mas não necessariamente) e uma variável dependente, de valor binário. As variáveis independentes são as de ambiente topográficas e as de ambiente espectral, enquanto as variáveis dependentes foram as imagens booleanas das amostras de treinamento, uma para cada classe específica, com valores binários de zero e um, indicando respectivamente ausência e presença da classe.

Utilizou-se o módulo LOGISTIREG do software IDRISI para realizar o processo de RLB, logo, optou-se por apresentar as etapas de cálculo das quais o referido software faz uso. A relação entre as variáveis dependentes e independentes é determinada pela expressão:

$$p(\theta = 1|X) = \frac{\exp\left(\sum_{k=0}^k BX\right)}{1 + \exp\left(\sum_{k=0}^k BX\right)} \quad (14)$$

onde p é a probabilidade da variável dependente (θ) sendo 1, X é o vetor de variáveis independentes tal que $X = (x_0, x_1, x_2, \dots, x_k)$, B é vetor dos coeficientes estimados tal que

$B = (\beta_0, \beta_1, \beta_2, \dots, \beta_k)$ e k é o número de variáveis independentes. Para linearizar a Equação (14) e eliminar os valores de probabilidade nos limites próximos de 0 e 1, emprega-se a transformação logística na forma: $p(\theta)' = \log\left(\frac{\theta}{1-\theta}\right)$. Como os valores $p(\theta)'$ podem assumir qualquer valor no intervalo de “-” a “+” infinito, aplica-se a transformação *logit* nos dois lados da equação, obtendo o modelo de regressão linear padrão:

$$\log\left[\frac{p}{1-p}\right] = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \alpha \quad (15)$$

com α sendo o termo que representa o resíduo do modelo.

As seguintes hipóteses simplificativas são assumidas para o modelo de regressão logística: 1) que a variável aleatória dependente θ seja binária; 2) que os resultados de θ sejam mutuamente exclusivos e exaustivos; 3) que θ seja dependente de k variáveis independentes X ; 4) que a relação entre θ e X não seja linear e obedeça a uma curva logística; 5) que os dados são gerados a partir de uma amostra aleatória de tamanho n ; 6) que as variáveis aleatórias independentes não sejam linearmente relacionadas, ou seja, $n > k$; 7) e que os resíduos (α) de cada observação sejam independentes dos resíduos de todas as demais observações.

Para resolver o melhor ajustamento do conjunto de parâmetros ou coeficientes da curva de regressão logística, o módulo LOGISTICREG emprega o método de estimação da máxima verossimilhança, na forma:

$$L(\theta) = \prod_{i=1}^n \theta_i^{y_i} (1-\theta_i)^{(1-y_i)} \quad (16)$$

onde L é a verossimilhança de θ , θ_i é o valor predito da variável dependente para a amostra i tal que $\theta_i = \text{logit}^{-1}(\theta_i) = e^{\theta_i} / (1 + e^{\theta_i})$, y_i é o valor observado da variável dependente para a amostra i . Com o intuito de maximizar a função de verossimilhança, deve-se solucionar as seguintes equações simultâneas não lineares: $\sum_{i=1}^n (y_i - \theta_i) x_{ij} = 0$, onde x_{ij} é o valor observado da variável independente j para a amostra i .

Com o modelo de equações da RLB solucionado pela Equação (16), pode-se aplicá-lo na Equação (13) e obter o modelo probabilístico beta-binomial, tal que:

$$p(\theta|\alpha, y, \beta, n) = [L(\theta)]^{y+\alpha-1} [1-L(\theta)]^{n-y+\beta-1} \quad (17)$$

Através do modelo apresentado na Equação (17) é possível se obter o valor da probabilidade corrigida para as variáveis consideradas, obedecendo ao paradigma Bayesiano. Em síntese, a Equação (17) considera y possibilidades de sucesso de se encontrar uma classe informacional específica em n possíveis tentativas (todas as classes informacionais), para cada pixel na área da imagem; além de permitir a expressão da opinião pessoal do analista sobre a forma da distribuição, através dos hiperparâmetros α e β , que representam respectivamente a posição e a dispersão da distribuição.

3. MATERIAL E MÉTODOS

3.1 Introdução.

Este capítulo é dedicado à apresentação das características dos dados bem como seu pré-processamento para torná-los disponíveis e adequados ao uso. É apresentada a metodologia proposta nesta pesquisa para modelagem do contexto de forma direta e de forma indireta, de modo que o resultado contribua efetivamente para melhorar o desempenho do algoritmo classificador. O tipo de modelagem está relacionado ao tipo de dados, que requer um tratamento particular. Dados do tipo booleanos são examinados na modelagem direta do contexto, dados tipo contínuos como os modelos de superfície e outros, são abordados na modelagem indireta. São apresentados também alguns critérios de consideração que devem ser observados na introdução de informações contextuais na análise. Esses critérios são úteis para ambos os casos de modelagem do contexto, seja direta ou indireta.

3.2 Área de estudos e características da base de dados.

Localizada aproximadamente entre as latitudes $\varphi:19^{\circ}43'S$ e $\varphi:20^{\circ}03'S$ e longitudes $\lambda:44^{\circ}04'O$ e $\lambda:43^{\circ}51'O$, a área de estudo definida foi o Limite Municipal de Belo Horizonte, cidade capital do Estado de Minas Gerais, localizada na mesorregião Metropolitana de Belo Horizonte. O município tem um perfil fortemente caracterizado por intensa ocupação urbana, desenvolvimento tecnológico e industrial em diversos setores de atividade, comércio e mineração. Além de concentrar o centro político-administrativo do Estado, Belo Horizonte apresentou na última contagem populacional, em 2007, cerca de 2.412.937 habitantes e área da unidade territorial de aproximadamente 331 km² (IBGE, 2007).

Em termos de caracterização física, apresenta relevo fortemente ondulado, rodeado por serras (a principal é a Serra do Curral) que compõem a Cordilheira do Espinhaço, com ocupação vegetal composta principalmente por Floresta Nativa (FN),

Floresta Plantada (FP), Cerrado(CE), Campo Cerrado (CC) e Campo Plantado (CP) (ver Tabela 1). A região exibe intensa rede de cursos d'água que configura malha rica em termos de recursos hídricos. Localizada na Bacia do Rio São Francisco, é atendida pelos Ribeirões Arruda e do Onça (afluentes do Rio das Velhas).

Belo Horizonte é uma cidade de marcante expressão cultural, educacional e de pesquisa. Não obstante sua importância para Minas Gerais, a definição como objeto de investigação e pesquisa foi motivada por: (i) sua configuração ocupacional ofereceu condições para aplicação da metodologia proposta na pesquisa e (ii) o mapa temático de vegetação produzido pela metodologia apresentada pôde atender à SMAMA, órgão da Prefeitura de Belo Horizonte (PBH). Além da SMAMA, outros órgãos da PBH estiveram envolvidos, contribuindo com o fornecimento dos dados fundamentais para realização do trabalho. As imagens de satélite foram gentilmente fornecidas pela Secretaria Municipal Adjunta de Regulação Urbana (SMARU), enquanto bases de dados vetoriais foram prontamente cedidas pela Empresa de Informática e Informação do Município de Belo Horizonte S.A. (PRODABEL).

Tabela 1 – Descrição das categorias de vegetação fornecida pelos técnicos da SMAMA dos temas a serem discriminados no mapa temático.

| Categoria | Descrição |
|---------------------------|--|
| Floresta nativa | vegetação de porte arbóreo denso onde as copas se tocam não proveniente de reflorestamento. |
| Floresta plantada | vegetação de porte arbóreo denso que tenha sido plantada. Pode ser uma plantação de eucalipto, um pomar, ou outro tipo de reflorestamento. |
| Cerrado | vegetação nativa típica com porte arbóreo pouco denso onde as copas pouco se tocam. |
| Campo cerrado | campo natural típico com arbustos esparsos. |
| Campo plantado (pasto) | gramíneas plantadas como pasto ou gramado. |
| Solo exposto | onde não há vegetação e nem construções. |
| Vegetação viária em ruas | as copas das árvores existentes em ruas e praças. |
| Quintais (fundos de lote) | copas das árvores e gramados de áreas particulares. |
| Área permeável | apenas a vegetação. Toda a área vegetada, seja em áreas públicas ou privadas. |
| Área impermeável | apenas construções. Toda a área construída como prédios, casas, estacionamentos, asfalto e outros. |
| Recursos hídricos | cursos d'água e lagoas |

Ficou estabelecido um termo de cooperação entre a SMAMA e a Universidade Federal de Viçosa (UFV), no qual o órgão da PBH mobilizou parte de seu corpo técnico, que prontamente deu suporte durante a realização da pesquisa. Os técnicos participaram ativamente do trabalho e seu conhecimento de campo contribuiu de modo fundamental. Auxiliaram na especificação e determinação das classes de vegetação a serem identificadas, bem como sua descrição, identificação e supervisão na etapa de coleta de amostras. Em contrapartida, o mapa temático de vegetação foi produzido de forma a atender aos requisitos e interesses da SMAMA.

Os planos de informação da base vetorial fornecidos pela PRODABEL se referiam aos seguintes temas: limite municipal e hidrografia, ilustradas na Figura 3; curvas de nível, exibidas na Figura 4; quadras e eixo das vias, apresentadas nas Figuras 5 e 6, respectivamente. As imagens fornecidas pela SMARU consistiam de cenas da plataforma orbital *QuickBird 2*, abrangendo toda a extensão territorial do município.




Figura 3 – Recursos hídricos e contornos do limite municipal de Belo Horizonte.




Figura 4 – Curvas de nível com equidistância vertical de 5 metros.




Figura 5 – Quadrantes originadas do cadastro técnico multifinalitário.




Figura 6 – Eixo das vias terrestres originadas do cadastro técnico multifinalitário.

As imagens utilizadas foram originalmente nomeadas conforme padrão do distribuidor. Para melhor compreensão no decorrer do texto bem como facilidade de exposição, foram renomeadas para “A”, “B”, “C”, “D” e “E”¹³ (Figura 7). As Características descritivas principais dessas imagens são mostradas na Tabela 2. Todas são produtos tipo Imagem Padrão. Devido às características do relevo da região, torna-se imprescindível submetê-las a ortorretificação, pois se tratando de relevo irregular, as distorções topográficas podem configurar efeito indesejado na qualidade das feições nas imagens.

¹³ Os nomes “A”, “B”, “C”, “D” e “E” correspondem, respectivamente, às seguintes identificações: 05oct10133032-m2as-005552894010_01,05oct10133033-m2as_005581794010_01_p001, 06jul15133145-m2as_r1c1-005537434020_01_p005,06jul15133145-m2as_r2c1-05537434020_01_p005, 06jun14133546-m2as_r4c1-005537434020_01_p004.




Figura 7 – Imagens Padrão *QuickBird* multiespectrais que definem a área de estudo (Município de Belo Horizonte-MG), em composição de cores naturais (bandas 1, 2 e 3 nas cores azul, verde e vermelha, respectivamente), dispostas em diferentes escalas para melhor apresentação.

Dentre as imagens, “A” e “B” se encontravam com resolução radiométrica reduzida para 8 bits, ou seja, apresentavam seus valores numéricos numa escala de 0 a 255 no lugar de estarem escalonados de 0 a 2047 (11 bits). As demais imagens (“C”,

“D” e “E”) foram também convertidas, cada banda, para mesma escala de valores de 8 bits através da equação de normalização:

$$VN_N = \left(\frac{VN_A - VN_{MIN}}{VN_{MAX} - VN_{MIN}} \right) * V_E \quad (18)$$

onde VN_N e VN_A são os valores numéricos novo e atual, VN_{MAX} e VN_{MIN} são os valores numéricos máximo e mínimo na banda espectral específica e V_E é o valor de escala, que no caso foi 255.

Ao observar a Tabela 2, percebe-se a diferença nas datas de aquisição das imagens variam de 1 até 10 meses. Essa diferença temporal pode evidenciar interferências devido a atmosfera. Tais interferências, aliadas às características inerentes de alteração sazonal das plantas, podem provocar o efeito de que um mesmo objeto apresente respostas espectrais muito diferentes¹⁴. Para evitar isso, foram realizados procedimentos de atenuação dos efeitos atmosféricos em todas as imagens. Atendendo aos requisitos do processo de classificação, todas as imagens foram agrupadas em uma única cena, de modo a representar a área completa do Município.

Tabela 2 – Algumas características descritivas obtidas a partir dos respectivos arquivos de metadados das imagens utilizadas.

| Parâmetros | Imagens | | | |
|----------------------------------|--------------------------------|--------------------------------|--------------------------------|--------------------------------|
| | “A” | “B” | *“C” e “D” | “E” |
| Início aquisição (data, hora) | 2005-10-10, 13:30:32.381369 | 2005-10-10, 13:30:32.381369 | 2006-07-15, 13:31:31.083943 | 2006-06-14, 13:35:33.279904 |
| Fim aquisição (data, hora) | 2005-10-10, 13:30:32.574982 | 2005-10-10, 13:30:33.409596 | 2006-07-15, 13:31:45.953610 | 2006-06-14, 13:35:46.562592 |
| Cobertura de nuvens (%) | 0 | 0 | 9,4 | 13,1 |
| Elevação base (m) | 877,56 | 895,59 | 904,53 | 904,67 |

*As imagens “C” e “D” foram unidas, pois são recortes de uma única aquisição e compartilham o mesmo arquivo metadados.

¹⁴ Quando se tratar de uma só imagem esses efeitos são geralmente desprezados, uma vez que a interferência é presumidamente proporcional para toda área.

3.3 Recursos computacionais e de software.

Todos os procedimentos realizados neste trabalho, seja na base de dados ou mesmo na redação, foram executados empregando dois microcomputadores pessoais, um de arquitetura desktop e outro de arquitetura portátil.

A configuração do micro desktop consistia de: um processador Pentium 4 com capacidade de processamento de 2,8 GHz; com 2,0 GB disponíveis de memória RAM; e disco rígido de 80 GB de capacidade física de armazenamento de dados. O desktop contava ainda com sistema operacional Windows XP, com os programas aplicativos *ArcInfo*, *Idrisi* e *Erdas*. Este ambiente foi utilizado para execução da maioria dos processamentos e operações matemáticas.

O microcomputador portátil dispunha da seguinte configuração de seus componentes: dois processadores Pentium com capacidade de processamento de 1,73 GHz cada; 1,0 GB de memória RAM (*Random Access Memory*) disponível; e disco rígido de 120 GB de memória física para armazenamento. Contava com os programas aplicativos 6S e *Kappa*, utilizados para atenuação atmosférica avaliação da qualidade da classificação temática, respectivamente. Dispunha instalado o sistema operacional Windows Vista Home Premium e editor de texto apropriado.

3.4 Preparação dos dados.

São apresentadas as etapas para a preparação dos dados, que se iniciou com edição dos planos de informação vetoriais para posterior conversão ao formato matricial. Após, apresenta-se os passos utilizados para produção de um modelo digital de elevação corrigido a partir da base hidrológica e também os processos de correção geométrica e atenuação atmosférica. Por fim, descrevem-se as variáveis de ambiente: topográficas e espectrais, e os meios de obtê-las, bem como os ajustes necessários para sua correta utilização na modelagem.

Os PIs vetoriais apresentavam suas coordenadas em projeção UTM, fuso 23, hemisfério sul, enquanto as imagens ofereciam também a opção de representação por coordenadas geodésicas. Foram obtidos por aerolevantamento e apresentavam resolução

da ordem de decímetros (PRODABEL, 2008). Esses arquivos encontravam-se no formato vetorial genérico *shapefile* (extensão *.shp), compatíveis a programas aplicativos que suportam tal formato (ArcView, ArcGis, entre outros). Além das características de referência mencionadas, seu *Datum* de referência é o SAD 69. As imagens da plataforma orbital *QuickBird 2*, por sua vez, apresentavam precisão inferior ao aerolevanteamento e foram obtidas do formato matricial genérico GeoTIFF (extensão *.tiff). Exibiam quase as mesmas condições de projeção plana que os planos de informação vetoriais, exceto por seu *Datum* de referência se tratar do WGS 84. Ou seja, os dados vetoriais e as imagens encontravam-se referenciados em sistemas diferentes. Como essa diferença pode causar inconsistência em operações de sobreposição (como é o caso), houve necessidade de aplicar transformações para se obter equivalência. As transformações foram aplicadas nas imagens e não nos planos de informação, pelo motivo da correção geométrica.

Em relação aos atributos das imagens, eles são explicados detalhadamente no Guia de Produtos de Imagens *QuickBird* (DIGITALGLOBE, 2007) ou resumidos no trabalho de Liedtke (2002). Para fins de objetividade, foram comentadas apenas as características de maior relevância para o trabalho, empregadas na metodologia. Na Tabela 3 são expostas as especificações gerais das resoluções que caracterizam as imagens *QuickBird*. A empresa responsável pelo fornecimento das imagens *QuickBird* oferece três tipos de produtos, conforme o nível de processamento: Imagem Básica; Imagem Padrão; e Imagem Ortoretificada. Em todos os produtos são feitas correções do sensor e radiométricas. As Imagens Padrão são corrigidas geometricamente com uma precisão associada de 82 metros (excluindo efeitos topográficos do terreno e do ângulo de visada) ao nível de confiança de 90%. Os produtos ortoretificados são corrigidos de distorções topográficas e suas precisões dependem da escala de correção, podendo variar de 25 metros para uma escala de 1:50.000 até 5 metros em uma escala de 1:10.000, ambos ao nível de confiança de 90%, segundo especificações da empresa.

A escolha de cada tipo de produto aponta para um determinado perfil de cliente que o adquire, num certo sentido, associado ao nível de processamento. Quanto menor for o nível de processamento do produto adquirido, por exemplo, no caso de uma Imagem Básica (bruta), mais avançado deve ser o conhecimento do cliente para proceder com o correto tratamento. Analogamente, quanto mais processada for a imagem adquirida, por exemplo, Imagem Ortoretificada, menor a necessidade do cliente conhecer técnicas e operações de pré-processamento de imagens.

Tabela 3 – Especificações gerais de resoluções de imagens produzidas pelo satélite artificial *QuickBird*.

| Banda | Região do Espectro Eletromagnético | Resolução | | | |
|-------|------------------------------------|-----------------------------|--------------|-----------------|---------------------|
| | | espectral (μm) | espacial (m) | temporal (dias) | radiométrica (bits) |
| 1 | *Azul (visível) | 0,4485 a | 2,44 (nadir) | 3 | 11 |
| | | 0,5123 | a 2,88 (25°) | | |
| 2 | *Verde (visível) | 0,4988 a | 2,44 (nadir) | 3 | 11 |
| | | 0,5941 | a 2,88 (25°) | | |
| 3 | *Vermelho (visível) | 0,6226 a | 2,44 (nadir) | 3 | 11 |
| | | 0,6889 | a 2,88 (25°) | | |
| 4 | *Infravermelho próximo | 0,7591 a | 2,44 (nadir) | 3 | 11 |
| | | 0,8634 | a 2,88 (25°) | | |
| PAN | Pancromática | 0,515 a | 0,61 (nadir) | 3 | 11 |
| | | 0,875 | a 0,72 (25°) | | |

*aproximadamente.

Fonte: adaptado de Liedtke (2002).

3.4.1 Edição vetorial.

Inicialmente, para que a conversão vetorial-matricial ocorresse de modo consistente, se fez necessária uma averiguação da condição dos planos de informação. Através de análise visual e sucessivas consultas ao banco de dados foram verificadas algumas falhas, que consumiram elevado tempo de edição para os vetores de plani-altimetria e hidrografia.

As curvas de nível da base plani-altimétrica apresentaram algumas feições desprovidas de valor numérico associado, ou seja, sem cotas altimétricas. Para esses casos específicos, algumas foram editadas (onde foi possível inferir seu valor a partir da equidistância vertical das curvas de nível - 5 metros), enquanto outras foram simplesmente suprimidas. A base hidrográfica exibia incoerência no sentido do escoamento dos cursos d'água por praticamente toda a extensão da área, além de não apresentar ligações em grande parte das feições (cursos d'água), comprometendo fortemente a construção topológica da informação. Em alguns trechos, os desenhos da rede hidrográfica exibiam ligações tão incoerentes que, se optou por não considerá-los. Toda edição vetorial foi realizada na plataforma de trabalho *ArcInfo*.

Demais planos de informação (vias, quadras e limite municipal) não apresentaram necessidade de correção, logo foram convertidos ao formato matricial diretamente. Para os propósitos deste trabalho, fez-se necessário gerar imagens a partir dos PIs com os mesmos parâmetros espaciais (tamanho do pixel, unidades de referência, sistema de projeção) que as imagens orbitais. No caso específico das curvas de nível a conversão direta não foi realizada, pois não se tratava da opção mais interessante. A vantagem em se converter curvas de nível para base matricial está em efetuar uma interpolação dos valores cotados nas curvas para obtenção de um modelo de elevação do terreno, capaz de caracterizar a superfície em termos de valores contínuos de altitude espacialmente distribuídos, fornecendo um perfil tridimensional da área.

3.4.2 Geração do Modelo Digital de Elevação (MDE).

As bases hidrográfica e plani-altimétrica foram editadas para serem utilizadas na geração de Modelo Digital de Elevação (MDE), servindo como parâmetro de entrada ao algoritmo¹⁵ de interpolação. Os planos de informação de entrada para o MDE foram a plani-altimetria, os cursos d'água, os contornos da Lagoa da Pampulha (polígono extraído da base hidrográfica) e o limite municipal. A exemplo dos demais PIs, o MDE produzido conservou o sistema de referência de origem vetorial (SAD 69) e foi interpolado com o tamanho do pixel¹⁶ (resolução espacial) idêntico ao das bandas multiespectrais do satélite *QuickBird* (ver Tabela 3).

Para processar os cálculos de interpolação para obtenção do MDE, em virtude da resolução espacial e do tamanho da área, foi necessária a redução do seu tamanho para atuação do algoritmo. Foi feita uma divisão dos PIs de curvas de nível, hidrografia e limite municipal em quatro partes aproximadamente iguais, que então foram

¹⁵ Dentre os algoritmos de interpolação disponíveis, optou-se pelo TOPOGRID (ESRI, 1997), disponível na plataforma *ArcInfo*. Esse algoritmo processa um ajustamento da superfície com base não apenas às curvas de nível, mas também os recursos hídricos que caracterizam a região (como lagos, cursos d'água) bem como o limite espacial que restringe sua área de atuação.

¹⁶ Empiricamente, tem se aceito a elaboração de MDEs com resolução espacial máxima de até metade da Equidistância Vertical (EV) das curvas de nível utilizadas na sua geração (EV = 5 metros). Houve uma extrapolação deste valor de resolução para o MDE gerado, uma vez que foi utilizado o mesmo tamanho de pixel das imagens multiespectrais *QuickBird* (Resolução Espacial = 2,4 metros). Tal atitude foi justificada pelo fato do MDE e seus modelos topográficos derivados terem sido necessários em operações entre imagens de mesmas dimensões.

processadas individualmente, gerando quatro MDEs que, após o processo foram agrupados formando uma só imagem de altitudes de todo o Município.

Incertezas posicionais dos planos de informações utilizados como entrada para elaboração do MDE não foram consideradas por não se conhecer sua verdadeira magnitude, portanto, nenhuma variação posicional foi atribuída ao produto gerado. Embora existam mecanismos para introduzir incertezas em modelos (geralmente através de RMS) como o MDE, uma nova série de hipóteses devem ser assumidas sem garantias que o produto computado esteja livre de tendências. Assim, preferiu-se tratá-lo com uma incerteza desconhecida, não contabilizada nos cálculos. Entretanto, discrepâncias comuns de interpolação puderam ser reduzidas por um algoritmo iterativo que torna o MDE Hidrologicamente Consistente (MDEHC), configurando um novo produto. O algoritmo remove depressões espúrias do MDE. Essas depressões são pixels centrais cujo valor numérico é muito inferior aos valores dos seus pixels vizinhos imediatos contíguos. Algoritmos com intuito de remover distorções típicas de interpolação podem ser mais ou menos eficientes no que concerne à economia de tempo gasto com sua execução. Para fins de monitorar todas as etapas de correção, foi utilizado o seguinte algoritmo, extraído e adaptado de ESRI (1997), para obtenção do MDEHC a partir do MDE:

- 1) Calcular a direção de escoamento a partir do MDE. Caso o resultado deste processamento apresente apenas os valores: [1, 2, 4, 8, 16, 32, 64, 128]¹⁷, o procedimento foi concluído e o MDE é na realidade o MDEHC. Caso apresente quaisquer outros valores, repetir (iterar) todos os passos até que a condição de satisfação seja alcançada;
- 2) Identificar as depressões espúrias a partir da direção de escoamento;
- 3) Delimitar a área de drenagem de cada depressão e identificar a menor cota na borda das depressões a partir da identificação das mesmas;
- 4) Preencher os pixels da área de drenagem de cada depressão com o valor da menor cota da respectiva área de drenagem;
- 5) Preencher os valores dos pixels com cotas inferiores à menor cota da borda da área de drenagem de uma depressão com o valor da menor cota da borda, eliminando as depressões espúrias;

¹⁷ Esses valores representam as possíveis direções [1(E), 2(SE), 4(S), 8(SO), 16(O), 32(NO), 64(N) e 128(NE)] de escoamento para o caso em que o MDE seja hidrologicamente consistente.

6) Substituir o relevo do modelo inicial com valores do relevo corrigido das depressões;

7) Repetir o passo 1 e observar o resultado.

Detalhes e aprofundamentos para produção de MDE e MDEHC são amplamente explorados no trabalho de Chaves (2002).

A importância de se obter o MDE mais consistente possível é devida ao seu papel no decorrer do trabalho, pois será empregado na geração de variáveis ambientais topográficas utilizadas na modelagem. Diversos programas aplicativos SIG (por exemplo: *ArcInfo*, *Idrisi*) oferecem módulos específicos para se conseguir consistência hidrológica de MDEs automaticamente. Mais detalhes sobre MDEHCs, meios de obtenção, formas mais simples de avaliação de suas precisões podem ser acessados em Chaves (2002) e Chagas (2006). Modelos mais rebuscados para correção e avaliação podem ser consultados em Zhu *et al.* (2005) e Aguilar *et al.* (2006), ou para maior refinamento da interpolação podem ser encontrados em Shi e Tian (2006).

3.4.3 Ortoretificação.

Inicialmente foi processado um agrupamento das imagens “C”, “D” e “E” (ver Figura 7) precedente à correção geométrica, sendo preferível, entretanto, que cada imagem fosse ajustada individualmente. Este procedimento justificou-se por dois motivos: 1) Somente um arquivo de metadados acompanhava as imagens “C” e “D”, logo não podiam ser corrigidas separadamente. Outro forte indicativo para sua união foi apresentarem áreas perfeitamente contíguas; 2) Apesar de se posicionar mais próxima da imagem “A”, a imagem “E” foi agrupada com a imagem “D” devido suas épocas de aquisição serem mais próximas, conforme pode ser constatado observando a Tabela 2. Além disso, apesar de possuir os metadados para ser corrigida individualmente, a imagem “E” necessitava de ser agrupada para ser corrigida pois, representa uma área pequena e completamente isolada, sem a possibilidade de se identificar Pontos de Controle (PC), seja na imagem multiespectral, seja nos PIs (ver Figura 7). Como o interesse deste trabalho foi direcionado mais à exploração das características espectrais do que às características espaciais, devido à classificação, considerou-se que a melhor

opção seria agrupar as imagens “C”, “D” e “E”, em oposição às imagens “E” e “A”, ou mesmo, às imagens “E” e “B”.

Cada imagem exigiu exaustiva coleção de pontos de controle, uma vez que o modelo RPC exige muitos pontos. É recomendado pelo menos o mínimo de pontos de controle requisitados para solução do modelo para se obter melhores resultados. Com este intuito, foram coletados PCs superabundantes (quantidade superior a 120 pontos) para as imagens “A”, “B” e o agrupamento “CDE”, de modo que, após a retirada dos piores pontos, nenhum ajuste fosse realizado com menos de 78 pontos. No conjunto de metadados foram fornecidos os arquivos com os valores dos coeficientes racionais polinomiais (*Rational Polynomial Coefficients - RPC*)¹⁸, empregados no modelo de funções racionais polinomiais (*Rational Polynomial Function - RPF*).

O critério empregado para considerar ou eliminar um PC específico foi observar seu valor particular de RMS, bem como sua contribuição para o RMS total computado. Assim, a eliminação dos PCs foi realizada iterativamente observando esses dois parâmetros (valor RMS individual do ponto e valor RMS total para o conjunto de pontos), eliminando os pontos que apresentaram os maiores valores de RMS. A condição assumida para satisfação da solução do modelo se deu para valores RMS em torno de 0,8. Foi observado que para todas as imagens este valor representou um patamar de estabilização. Ao considerar que o RMS é expresso nas mesmas unidades de referência da imagem, significa dizer que há um erro médio de ajustamento de 0,8 unidades de referência da imagem (metros) e, portanto pode-se constatar que o erro está abaixo do padrão norte-americano para valores RMS máximos aceitáveis (para o caso seria em torno de 1,2 metros ou ½ pixel). Para todas as imagens (“A”, “B” e o agrupamento “CDE”), o valor RMS assumido aceitável foi alcançado com número de no mínimo 78 PCs. Os pontos foram colecionados especificamente sobre o PI **trechoctm**, que representa a malha viária do Município. Algumas interseções de vias configuram boa fonte de referência para aquisição de PC que, graças à característica própria (física) de intensa urbanização do Município de Belo Horizonte, foi possível ampla distribuição de pontos por toda a área (situação ideal).

As precisões dos PIs da base vetorial não eram conhecidas e os PCs coletados não foram verificados em campo. Logo, a precisão obtida com a avaliação do RMS trata-se apenas de uma medida relativa da qualidade posicional obtida com o procedimento.

¹⁸ Os arquivos que contem a informação dos coeficientes racionais polinomiais constantes nos metadados das imagens *QuickBird* recebem o nome de RPB, uma contração do nome RPC00B.

Para maiores detalhes sobre como a precisão se altera em função do número de PC e suas respectivas variâncias quando consideradas no modelo, pode-se consultar Fraser *et al.* (2006). Apesar de não ter sido possível modelar as discrepâncias posicionais, pode-se ter idéia de sua grandeza total considerando o erro médio do ajuste geométrico (RMS $\pm 0,8$) propagado para o valor da precisão garantida pelo fornecedor no contrato, caso se venha a conhecer tal valor.

Realizou-se a operação de ortorretificação pelo software ERDAS, empregando o modelo de ajuste RPC, com os coeficientes racionais polinomiais disponíveis no arquivo RPB (RPC00B) e o MDEHC. A partir do MDEHC, foi possível corrigir as distorções provocadas pela topografia do terreno. A imagem de entrada se encontrava no sistema de referência WGS 84. Para a imagem de saída foi ajustado o sistema de projeção UTM, com unidades de referência métricas e sistema de referência SAD 69 (Brasil), fuso 23, zona K, meridiano central -45, hemisfério Sul. Empregou-se a opção de refinamento polinomial de terceira ordem para o ajuste do modelo.

Os valores apresentados na Tabela 4 apresentam os erros totais de ajuste do modelo para as imagens “A”, “B” e “CDE”. Detalhes sobre os valores dos parâmetros processados podem ser acessados no Apêndice A, onde valores específicos para as imagens “A”, “B” e “CDE” encontram-se nos Apêndices A1, A2 e A3, respectivamente.

As incertezas posicionais obtidas pelo processo de correção através do modelo RPC indicaram um ajuste de qualidade aceitável, pois, os valores de RMS ficaram abaixo dos valores máximos admitidos por padrões norte-americanos, considerados padrões de referência internacionais.

Tabela 4 – Erros dos Pontos de Controle para as imagens “A”, “B” e “CDE”.

| Erros dos Pontos de Controle | Imagens | | |
|------------------------------|---------|--------|--------|
| | A | B | CDE |
| em X | 0,5108 | 0,5580 | 0,5262 |
| em Y | 0,6360 | 0,5902 | 0,6117 |
| RMS total | 0,8158 | 0,8122 | 0,8069 |

Apesar da qualidade do ajuste, ressalta-se que não houve verificação em campo dos PCs para quantificar de maneira adequada a qualidade posicional da imagem

ortorretificada. Portanto, a medida do RMS encontrado reflete o ajuste em função somente do plano de informação utilizado como referência, logo é uma medida de qualidade relativa a esse plano.

3.4.4 Correção atmosférica.

Apesar do modelo 6S ter sido escolhido para o processo de atenuação atmosférica das imagens devido à sua comprovada e divulgada eficiência na correção de imagens, não foi encontrada referência alguma sobre esse modelo aplicado às imagens de resolução espacial muito alta, como é o caso das imagens *QuickBird*. No entanto, não há motivo para restrição de sua aplicação a essas imagens, uma vez que o modelo manipula valores observados de REM e esta não é seletiva à resolução espacial.

O processamento das imagens pelo modelo 6S foi realizado em um programa adaptado (ANTUNES, 2001) ao ambiente Windows para manipular imagens binárias brutas¹⁹. O programa adaptado diferencia-se do original no que diz respeito a dois parâmetros de entrada: 1) quanto à calibração dos sensores (*gain* e *offset*), que no seu código são processados com valores divulgados após julho de 2000; 2) e quanto à necessidade de informar o número de pixels da imagem (obtido pelo produto do número de linhas pelo número de colunas) (NCAVEO, 2005). Na adaptação há ainda uma supressão da opção de correção do valor da reflectância no Topo da Atmosfera (*Top Of Atmosphere – TOA*).

Antes de definir quais parâmetros utilizar, observou-se para os quais havia informações disponíveis e se essas informações eram apropriadas para inserção no modelo. Isto porque a entrada de parâmetros não é fixa, podendo variar conforme as opções escolhidas pelo analista. Para o ajuste das imagens *QuickBird* pelo modelo 6S foram utilizados nove parâmetros: - condições geométricas; - modelo atmosférico; - modelo de aerossol; - visibilidade horizontal em quilômetros; - altitude média do alvo em quilômetros; - indicação se o sensor é aerotransportado ou orbital; - intervalo de valores (inferior e superior) que definem a largura da banda espectral; - indicação da escala de valores de reflectância; e - número de pixels na imagem (definem sua dimensão).

¹⁹ Imagens sem cabeçalho que contêm apenas os valores numéricos dos pixels.

Os valores apresentados na Tabela 5 são referentes aos parâmetros de entrada no programa para correção das imagens “A”, “B” e “CDE”. Em relação ao item (i), não há indicação na relação de opções do programa para condições geométricas de observação do satélite *QuickBird*, logo a opção foi definir tais condições a partir dos metadados para cada imagem. O item (ii) refere-se ao modelo de atmosfera a ser utilizado na correção. Foi escolhido o Tropical pelo fato de ser a opção mais apropriada entre as disponíveis e pela região imageada se encontrar na região dos trópicos. Além do que, para utilizar a opção definida pelo usuário não havia dados suficientes à disposição para definir o modelo de atmosfera próprio. Os dois itens subsequentes, (iii) e (iv), são utilizados condicionalmente e referem-se ao modelo de aerossol a ser usado e à visibilidade horizontal da área (que representa a concentração de aerossol). Como não foi escolhido modelo de aerossol, conseqüentemente a opção de informar a visibilidade foi desprezada. Não utilizou-se modelo de aerossol basicamente por dois motivos:

- 1) uma consulta aos dados da estação meteorológica automatizada de Contagem-MG (a única mais próxima e com disponibilidade de dados para todas as datas de aquisição das imagens) não apresentou medições do parâmetro visibilidade;
- 2) a visibilidade está diretamente correlacionada à umidade relativa do ar (ver detalhes em Pinto (2001)), de forma que para valores inferiores a 60% desse parâmetro, seu efeito interferente na visibilidade pode ser desprezado. O maior valor de umidade relativa para uma das datas (dia 15/07/2006) de aquisição foi de 60,5%, logo, interpretou-se como praticamente livre do efeito de aerossóis.

O item (v) refere-se à altitude média do alvo em relação ao nível do mar, cujo valor informado foi obtido no arquivo de metadados, no campo correção da elevação (Tabela 2). O item (vi) solicita indicação se o sensor é aerotransportado ou orbital. Caso fosse aerotransportado, a altitude deveria ser informada, como foi orbital, tratou-se apenas de um valor padrão para esta situação. No item (vii) foram especificados os valores que definem a largura do comprimento de onda de cada banda, nas regiões aproximadas do azul, verde, vermelho e infravermelho próximo do *QuickBird*. Como não havia cadastro desses comprimentos específicos nas opções do programa, optou-se por informá-los individualmente, utilizando os valores de limite inferior e superior, apresentados da Tabela 3. Segundo Liedtke (2002), esses são os valores reais dos comprimentos de onda disponíveis no *QuickBird*. Quanto aos itens (viii) e (ix) referem-se respectivamente a qual intervalo encontram-se escalonados os valores de reflectância

da imagem e qual é seu número de pixels. Neste caso, todas as bandas das imagens encontravam-se escalonadas entre 0 e 255.

Tabela 5 – Síntese dos dados para atenuação atmosférica.

| Parâmetros de Entrada no Programa 6S | Conjunto de Imagens MS | | |
|--|------------------------|----------|-----------|
| | A | B | CDE |
| (i) Condições geométricas: valor 0 indica definição pelo usuário | 0 | 0 | 0 |
| Ângulo zenital solar | 21,8° | 21,8° | 46.7 |
| Ângulo azimutal solar | 56,1° | 55,9° | 29.2 |
| Ângulo zenital de visada | 19,6° | 20,1° | 8.7 |
| Ângulo azimutal de visada | 34,42° | 34,13° | 47.7 |
| Mês | 10 | 10 | 7 |
| Dia | 10 | 10 | 15 |
| (ii) Modelo de atmosfera: tropical | 1 | 1 | 1 |
| (iii) Modelo de aerossol: não utilizado | 0 | 0 | 0 |
| (iv) Visibilidade: desconsiderada devido ao item (iii) (valor <i>Flag</i>) | -1 | -1 | -1 |
| (v) Altitude do alvo em Km com sinal negativo | -0,877 | -0,895 | -0,904 |
| (vi) Indicação que o sensor é orbital | -1000 | -1000 | -1000 |
| (vii) Definição do intervalo de valores de comprimentos de onda que define cada banda espectral: informados pelo usuário | 0 | 0 | 0 |
| Limite inferior (em μm) | * | * | * |
| Limite superior (em μm) | * | * | * |
| (viii) Indicação da escala de valores reflectância: entre 0 e 255 | -1 | -1 | -1 |
| (ix) Número de pixels da imagem | 50412780 | 33329982 | 102310505 |

* Os valores utilizados para definir cada banda (azul, verde, vermelho e infravermelho próximo) foram aqueles apresentados para as resoluções espectrais das imagens multiespectrais *QuickBird* disponíveis na Tabela 3.

Uma vez definidos os parâmetros, as imagens já ortorretificadas foram convertidas em imagens brutas e então submetidas ao modelo de atenuação atmosférica 6S. Como entrada o programa requer um arquivo chamado “inpfiles.txt”(exemplo no

Apêndice B1) preenchido em quatro linhas, com cada linha informando nomes de arquivo referentes a: (i) entrada com as condições atmosféricas (*.txt) (exemplo disponível no Apêndice B2); (ii) condições atmosféricas calculadas de saída (*.res) (exemplo no Apêndice B3); (iii) imagem de entrada (*.raw) e (iv) imagem de saída corrigida (*.raw). O item (i) é um arquivo no qual cada linha corresponde a uma coluna de valores de imagem da Tabela 5, obviamente alterando o valor de cada comprimento de onda para a banda específica sendo corrigida.

Ao observar os valores dos parâmetros de entrada no programa 6S para os conjuntos de imagens multiespectrais (azul, verde, vermelho, infravermelho próximo) “A”, “B” e o agrupamento “CDE”, nota-se que o modelo de aerossol não foi utilizado para nenhuma das imagens. Cada coluna do conjunto de imagens representa um arquivo referente à uma banda espectral específica, portanto são necessários quatro arquivos para corrigir cada conjunto. Nesses arquivos, os valores são dispostos em linhas conforme abaixo, apenas as condições geométricas são dispostas diferentemente, em uma única linha após a primeira e seus valores separados por espaços.

Como saída, o programa calculou: (i) ângulos de espalhamento e de diferença azimutal, computados a partir dos parâmetros geométricos; (ii) conteúdo de vapor d’água (g/cm^2) e de ozônio (cm-atm) e também da pressão na superfície (milibars) computados a partir da altitude do alvo (em km) e do modelo de atmosfera escolhido. Exemplos de arquivos de entrada e saída utilizados no programa 6S adaptado estão acessíveis no Apêndice B.

A atenuação atmosférica garante o uso quantitativo dos valores multiespectrais sem restrições, ou seja, em situações propícias para processo de classificação. Em relação ao programa utilizado, mostrou ser eficiente, fácil e amigável ao usuário. No entanto, como foi compilado para executar em ambiente Windows 95 e 98, em ambientes superiores, recomenda-se ajustar a compatibilidade nas propriedades do arquivo executável para uma das versões mencionadas.

Ressalta-se que todos os parâmetros entrados no programa 6S adaptado foram verificados antes e obtidos por fontes confiáveis (metadados, literatura e órgão público). Os parâmetros não informados foram assim justificados pelas condições atmosféricas verificadas no instante da aquisição da imagem, através da consulta aos dados da Estação Climatológica do Instituto Nacional de Meteorologia (INMET) de Contagem-MG. De modo geral, recomenda-se cautela na escolha e na entrada dos parâmetros no modelo 6S, a fim de evitar equívocos.

3.4.5 Definição e refinamento das informações contextuais.

O MDEHC produzido anteriormente neste trabalho foi utilizado para a ortorretificação das imagens e foi considerado adequado ao uso e derivação de produtos para serem empregados como informações contextuais na análise. Vale mencionar que há métodos quantitativos de avaliação de MDEs muito robustos e precisos (ZHU *et al.*, 2005; AGUIAR *et al.*, 2006; SHI e TIAN, 2006), entretanto não foram empregados. Como o trabalho se ocupa da questão de identificação de objetos, não exige métrica. Logo, o importante foi dar mais atenção à radiometria e menos à geometria.

As informações contextuais utilizadas na modelagem indireta podem ser categorizadas como variáveis de ambiente: topográficas e espectrais. As variáveis topográficas foram o MDEHC e seus produtos derivados como Modelo Digital de Declividades (MDD) e o Modelo Digital de Azimute (MDA) da face de maior declividade. O MDA foi produzido em uma etapa intermediária para geração de outros dois produtos. A partir dos valores MDA foram derivados o Modelo Digital de faces Norte (MDN) e o Modelo Digital de faces Leste (MDL), obtidos por operações trigonométricas de cosseno e seno, respectivamente, representando as componentes angulares do MDA (maiores detalhes sobre esses componentes derivados do MDA podem ser encontrados em Domaç e Süzen (2006)). O cosseno dos valores angulares do MDA forneceu o MDN com valores escalonados de -1 a +1, onde os mais próximos de 1 representam as faces do terreno que são voltadas para o Norte e os valores negativos próximos de -1 representam as faces voltadas para o Sul. Valores próximos de zero, positivos ou negativos representavam a superfície plana. O mesmo raciocínio é aplicado para a operação de seno com valores de MDA, porém os maiores e menores valores (+1 e -1) do MDL representavam respectivamente as faces Leste e Oeste do terreno. A mesma interpretação do MDN quanto aos valores próximos de zero é dada ao MDL, ou seja, representam superfície plana. A variável espectral utilizada foi o NDVI.

Uma vez derivadas, as variáveis foram submetidas a uma inspeção visual qualitativa antes de se prosseguir com as análises, para verificação da consistência das imagens geradas. Essa inspeção verificou discrepância nos valores de MDD por toda a extensão do limite do Município. Os pixels nessa área linear exibiam leitura de valores

de 198% e 199%, o que representa uma convergência ao infinito (equivalente a aproximadamente 90°) em termos de declividade. Esses pixels de valores discrepantes eram capazes de introduzir tendências no modelo, pois se tratavam de importâncias superestimadas. Tratou-se do efeito de borda na determinação da Declividade. Acredita-se que esse efeito apareceu, provavelmente, no cálculo do valor de declividade do último pixel válido que limita o polígono da área de interesse, cujo vizinho imediato é um pixel de valor geralmente inválido, representado comumente por valores 0 ou -9999. A partir daí, foram constatados outros dois problemas: (i) o valor zero não se trata de um valor inválido para a grandeza declividade, pois representa as áreas planas e sua ocorrência na superfície válida, porém acontece comumente acompanhada de mudança gradual²⁰ de valores; (ii) os algoritmos para determinação de declividades geralmente não limitam sua área de atuação, computando esses valores como válidos, o que causa, em alguns casos, uma discrepância de significativa magnitude por toda a extensão limitante. O número de pixels que apresentavam essa característica foi de 131.204 unidades. Como na prática esses pixels representam valores irrealistas, pois tendem ao infinito, obviamente houve necessidade de removê-los do MDD para não comprometer o método proposto. Empregou-se o software ERDAS para realizar as operações de remoção. Como um único pixel do MDD é um quadrado de lado medindo 2,4m e isto representa por volta de 5,76m² em unidades de área, equivale dizer que foram eliminados 0,7557351Km² dos aproximados 331 Km² de área do Município, o que representa uma perda de 0,2283% da área útil de estudo do MDD. Para remover os valores de pixels discrepantes foi realizado um processo de reclassificação na imagem do MDD, ajustando os valores discrepantes para zero. Entretanto, a remoção dos pixels de borda trouxe outro efeito indesejável e também comprometedor à integridade da análise, que foi a redução de área efetiva. Além dessa diferença, foi verificado que nem todos os planos de informação convertidos para imagens, embora de mesmas dimensões, coincidiam com os limites da área que define o Município. As imagens orbitais apresentavam maior coincidência com o MDEHC embora nem tanta com o plano de informações de quadras.

Admitiu-se que a melhor opção seria a equiparação de área de atuação das demais variáveis para coincidir com o MDD, por uma operação de refinamento. Para isso, foi elaborado empiricamente um algoritmo para produzir uma imagem booleana, resultante do produto das intersecções de todos os PIs empregados na análise. Essa imagem foi

²⁰ Para ser válido, seria como se seu valor de declividade representasse a borda de um penhasco. Em outra situação, pode ser constatado como erro.

utilizada em operações aritméticas de multiplicação com cada plano de informação ou imagem orbital, redefinindo uma nova área de atuação. O algoritmo foi executado como segue:

- (i) definiu-se um número escalar arbitrário tal que seu valor em uma operação de adição com qualquer das imagens não permitisse valores negativos como resultado (utilizou-se o valor arbitrário 1000);
- (ii) somou-se o valor escalar para cada imagem do conjunto que se pretendia a intersecção (MDEHC, MDD, MDA, NDVI, Imagens orbitais corrigidas);
- (iii) realizou-se operação lógica *and* de cada resultado de (ii) com uma mesma imagem limite de referência (o limite municipal);
- (iv) processou-se uma única operação lógica *and* entre todos os resultados de (iii), e produziu-se a imagem booleana de área comum.
- (v) com a imagem booleana obtida em (iv) realizaram-se operações aritméticas de multiplicação em cada imagem que participaria das análises.

Como a operação aritmética de multiplicação envolveu todas as variáveis envolvidas, garantiu-se que todos os produtos apresentassem a mesma área útil e, conseqüentemente, integridade na operação. Um novo conjunto de imagens com novas dimensões de cobertura espacial foi então definido para todas as variáveis envolvidas. Na ilustração da Figura 8 é apresentada a variável de ambiente espectral NDVI.




Figura 8 – Variável de ambiente espectral NDVI. Os menores valores são apresentados em tons marrons e os maiores valores em tons verdes.

Na Figura 9 é apresentada a variável de ambiente topográfica MDEHC. A variável MDD, primeira derivada do MDEHC é exibida na ilustração da Figura 10. As ilustrações na Figura 11 exibem o MDN e as ilustrações apresentadas na Figura 12 mostram o MDL, ambas são primeiras derivadas de MDA e segundas derivadas do MDEHC.




Figura 9 – Variável de ambiente topográfica MDEHC, menores valores nas cores em tons de azul escuro e maiores valores em cores avermelhadas.




Figura 10 – Variável de ambiente topográfica MDD com menores valores nas cores em tons de azul escuro e maiores valores em cores de tons avermelhados.




Figura 11 - Variável de ambiente topográfica MDN com menores valores exibidos em tons escuros de cinza, e maiores valores mostrados em tons claros de cinza.




Figura 12 - Variável de ambiente topográfica MDL cujos menores valores são exibidos em tons de cinza escuro e maiores valores mostrados em tons de cinza claro.

3.4.6 Amostragem e avaliação da classificação.

Foram utilizados no mínimo 1.200 pixels por classe para extrair as assinaturas espectrais. A imagem de referência utilizada na avaliação foi produzida pela estratégia de refinamento da amostragem de treinamento, utilizando o critério da distância estatística de *Mahalanobis*²¹ no espaço de feições com um valor limiar de 50%, escolhido arbitrariamente. Ou seja, foi produzida uma nova imagem para teste, derivada

²¹ A Distância de *Mahalanobis* pode ser obtida pela fórmula: $D^2 = (x_m - \bar{x})^T S^{-1} (x_m - \bar{x})$ onde m é índice contendo as classes, x_m é vetor pixel com valor da classe, \bar{x} é o vetor de média da classe e S é a matriz de variância-covariância da classe (MATHER, 2004).

do refinamento da imagem de amostras de treinamento pelo critério estatístico da distância de *Mahalanobis*, em que pixels com distância estatística igual ou inferior à metade da distância máxima foram aceitos na nova imagem e pixels com distâncias superiores foram desprezados. Espera-se que este procedimento permita desconsiderar possíveis erros grosseiros cometidos pelo analista durante a coleção de amostras agrupadas, sem, contudo, introduzir tendência na avaliação dos resultados. Para a comparação dos resultados obtidos entre os métodos de classificação, foi calculado coeficiente *Kappa* (Equação (4)) e sua respectiva variância (Equação (5)) para cada produto temático gerado pela classificação. De posse desses valores, foi realizada sua posterior comparação pelo teste estatístico Z (Equação (6)).

3.5 Modelagem direta do contexto.

Neste trabalho, utilizou-se a abordagem de modelagem direta ou indireta do contexto, relacionado-a com a forma de representação da informação contextual, que pode ser comumente representada por variáveis com valores de dados dos tipos discretos ou contínuos. Neste tópico é abordado apenas o tratamento para dados do tipo discretos. Todavia, são apresentados alguns critérios que devem ser observados antes da introdução de qualquer tipo de informação contextual, e estes devem ser aplicados para ambos os casos de modelagem do contexto, quer seja de forma direta, quer seja de forma indireta.

A idéia fundamental da abordagem direta foi evidenciar a informação contextual num espaço geográfico, de modo a auxiliar na discriminação de uma classe informacional qualquer em um processo de classificação de imagens. Acredita-se que, para serem corretamente modeladas, as informações contextuais devem ser elencadas conforme atendam aos seguintes critérios:

- (i) de escala – faz referência ao nível de detalhamento necessário para representação da informação de forma apropriada. Pode-se questionar se a escala na qual a informação contextual está disponível seja compatível para sua representação adequada;

- (ii) de relevância – refere-se à pertinência da informação contextual como agente condicionante da classe-objetivo. A adequabilidade ou grau de inter-relação condicional que a informação contextual exibe em função da classe-objetivo que se pretende obter;
- (iii) de mensuração – diz respeito à propriedade da informação contextual ser expressa numericamente, quantificada em escala representável;
- (iv) de espacialização – refere-se a capacidade de representação espacial da informação contextual, preferivelmente na forma de mapa.

Analisando as descrições apresentadas na Tabela 1, pode-se deduzir que algumas das classes informacionais descritas possam ser distinguidas somente ao se considerar informações contextuais. Vegetação viária, vegetação em quintais, área permeável e área impermeável são exemplos. Certamente que um algoritmo classificador convencional não será capaz de discernir entre tipos de vegetações apenas por sua localização, como os que ocorram em ruas ou nos quintais das casas (fundos de lotes).

No caso do contexto vegetação em vias e quintais, foram estabelecidas quais as informações eram mais relevantes (áreas de vegetação, vias e quintais). Como o objetivo foi caracterizar o contexto vegetação sem se preocupar em definir seus diferentes tipos, elegeu-se, com base em experimentação, a variável espectral NDVI (Figura 8). Primeiramente foram coletadas amostras de treinamento para as cinco classes informacionais: floresta nativa, floresta plantada, cerrado, campo cerrado e campo plantado (pasto). As amostras de treinamento das classes de vegetação foram agrupadas para elaboração de um histograma de valores NDVI, a fim de se verificar sua densidade de distribuição e obter parâmetros estatísticos suficientes para definir sua ocorrência. O histograma e os parâmetros estatísticos média ($\mu = 0,686$) e desvio padrão ($\sigma = 0,179$), entre outros, podem ser observados na ilustração da Figura 13. Esses parâmetros foram utilizados como critério para estabelecer limites de valores NDVI que definiram todos os tipos de vegetação.




Figura 13 – Ilustração do histograma de valores NDVI para áreas de classes de vegetação mostrando a densidade da distribuição concentrada nos maiores valores. Podem ser verificados ainda alguns parâmetros estatísticos entre os quais, média e desvio padrão.

Verificou-se através do histograma, que, aparentemente forma uma certa simetria, maior densidade de distribuição das classes de vegetação para maiores valores NDVI. Pela distribuição, foi possível utilizar como critério de definição de vegetação um valor limite como referência, a partir do qual todas as classes de vegetação amostradas fossem incluídas. Esse valor foi definido nos termos da seguinte equação:

$$V_{\text{Ref}} = \mu_{\text{NDVI}} - 2\sigma_{\text{NDVI}} \quad (19)$$

em que μ_{NDVI} é média de valores NDVI nas amostras de treinamento dos tipos de vegetação e σ_{NDVI} seu desvio padrão, representando um nível de confiança de cerca de 95%. Aplicando-se, pois a Equação (19), obteve-se o valor limiar inferior de referência para caracterização de vegetação $V_{\text{Ref}} = 0,328$. O passo seguinte foi processar uma reclassificação booleana dos valores NDVI com base nesse valor de referência estimado, atribuindo zero para valores inferiores a ele e um para os demais. Todos os pixels com valores de NDVI superiores ao limiar de referência pertencem a algum dos tipos de vegetação enquanto todos abaixo desse limiar, não. A imagem booleana obtida define as áreas de ocorrência de vegetação e pode ser verificada na ilustração da Figura 14. Desse modo, encontra-se estabelecida a classe área permeável (desconsiderando solo exposto), obtida diretamente na operação de reclassificação realizada para determinação de áreas de vegetação.




Figura 14 – Imagem booleana evidenciando áreas de vegetação na cor preta e de não vegetação na cor branca, obtida pelo processo de reclassificação de valores NDVI.

Houve, porém, um detalhe na descrição da categoria “quintais” apresentada na Tabela 1, que dificultou a obtenção da classe vegetação em quintais pela simples intersecção de quadras com a imagem booleana de vegetação. Esse detalhe foi a designação do adjetivo “particulares” atribuído a quintais. Diferenciar quais polígonos de quadras do plano de informação **quadrasctm** eram efetivamente particulares (em oposição a públicos), sem qualquer outro tipo de informação além das espaciais, foi somente possível ao se arbitrar um critério de escolha. Para obter o novo PI de quadras particulares, realizou-se uma inspeção visual por toda extensão da área de estudo através de sobreposição do PI **quadrasctm** vetorial à composição colorida da imagem *QuickBird*. As quadras onde se verificavam as condições de áreas isoladas foram removidas, de modo que as restantes eram, em tese, quadras particulares. Foram

excluídos os polígonos mais próximos às bordas que limitam a área do Município e ao final desse processo, o novo PI vetorial foi convertido para o formato matricial.

Devido às características de conversão vetorial/matricial de feições lineares, a imagem de vias produzida não era adequada à representação dessa feição por contemplar somente o eixo e não a largura da via. Para determinar as vias, realizou-se inspeção visual sobre a imagem de vias e quadras, verificando a medida de largura em diversos trechos, com objetivo de se conhecer um valor médio que representasse as larguras do maior número de vias. O valor médio verificado foi de 36 metros. Aplicou-se então o operador de distâncias euclidianas no PI **trechoctm** para calcular 18 metros a partir do eixo das vias em sentido às suas margens.

Verificou-se que a informação contextual de vias e quintais apresenta relação funcional com o mapa de vegetação por meio de intersecção. Isso possibilitou que a classes de vegetação viária em vias e quadras fossem obtidas pela fórmula:

$$R_i = (Y_i \cap V) \quad (20)$$

em que R_i é o resultado da operação lógica de intersecção do mapa de vegetação (V) com o respectivo PI (Y_i), sendo $i = ruas, quintais$. Para este caso, a introdução do contexto (i) foi capaz de identificar a classe objetivo de forma direta.

No caso das vias ocorreu que, pelo fato de ter se considerado um valor médio para os leitos, houve áreas em que os 36 metros foram mais que suficientes (vias secundárias). Em outros casos, porém, esse valor não foi suficiente (algumas vias arteriais) para representar o leito. Contudo, o maior inconveniente se verificou nas vias secundárias, caso em que houve sobreposição de área com a quadra. Para evitar uma superestimação dessas áreas, realizou-se uma pequena alteração na Equação (20) conduzindo a:

$$R = (\bar{Y}_q \cap Y_i) \cap V \quad (21)$$

em que o termo \bar{Y}_q é o inverso do plano de informação **quadrasctm** editado, Y_i é o plano de informação do leito das vias e V é a vegetação (Figura 14).

3.6 Modelagem indireta do contexto.

Considerando-se a descrição na Tabela 1 das classes referentes a florestas nativas e plantadas, nota-se que ambas apresentam semelhante porte arbóreo de alta densidade e a única informação que, *a priori*, realmente as diferencia é o fato de terem sido plantadas ou não. Para distingui-las, pode-se construir um modelo contextual que seja associado à ocorrência de cada categoria, com argumentos fundamentados na observação de outros locais onde sejam encontrados reflorestamentos e florestas naturais, para então fazer pressuposições com base na experiência. Por exemplo, pode ser considerado que as florestas plantadas (reflorestamentos) sejam provavelmente encontradas em regiões que ofereçam melhores condições de acessibilidade (de máquinas ou mesmo pessoas) do que em regiões de difícil acesso. Ou seja, elabora-se um contexto (no caso, acessibilidade) para determinação de florestas plantadas. Então, começa-se a levantar as variáveis que definem um ambiente de diferentes graus de acessibilidade. Pode-se argumentar que a declividade seja uma variável de ambiente topográfico que traz informação contextual de grande relevância para diferenciar as categorias, uma vez que as florestas nativas são observadas nas condições topográficas mais diferenciadas. Entretanto, valores de mapas de declividade ocorrem continuamente pela superfície (assim como as classes de florestas) e estabelecer um limiar de inclusão/exclusão (como no caso da modelagem direta) de ocorrência da classe poderia prejudicar mais que ajudar. Resta então a opção de modelá-lo integralmente, considerando sua característica de distribuição espacial contínua de valores.

De acordo com o modelo proposto pela Equação (17), o primeiro passo para modelar o contexto com dados contínuos foi realizar uma Regressão Logística Binomial (RLB) com as informações contextuais (variáveis de ambiente). Dentre as variáveis de ambiente disponíveis, foram escolhidas as que mais se adequavam a representar cada classe de vegetação com base na combinação de informações fornecidas pelos especialistas (SMAMA) com experiência do analista.

A área de atuação da RLB foi delimitada pela região exclusivamente de vegetação (Figura 14) a fim de evitar seu processamento fora das áreas de interesse, pois se trata de um processamento de elevado custo tempo-computacional. A RLB teve a qualidade de seu ajustamento avaliada no intuito de se conhecer a adequabilidade das variáveis independentes utilizadas na análise de regressão.

Para avaliar a qualidade do ajustamento da RLB, optou-se pelo parâmetro ROC (*Relative Operating Characteristic*) entre os disponíveis, por ser considerado excelente para medir a qualidade de um ajustamento de regressão logística (IDRISI, 2006). O procedimento ROC requer duas imagens, uma delas com valores contínuos cujos maiores representam maior verossimilhança da classe estar presente. A outra, uma imagem booleana de referência, com valores um e zero indicando a presença e ausência da classe, respectivamente. ROC emprega limiares (estabelecidos pelo analista ou definidos automaticamente) que indicam a quantidade de pixels com valor válido na imagem de verossimilhança, utilizados na comparação com a imagem booleana. Esses limiares são cumulativos no intervalo de 1% a 100%. Para cada limiar, duas variáveis são geradas e associadas a um ponto, onde X representa a taxa de positivos falsos, e Y , a taxa de positivos verdadeiros. Os valores de X e Y são utilizados para formar uma curva, cuja área é calculada para determinar o valor ROC. Valores ROC variam no intervalo de 0 a 1, em que 1 indica um perfeito ajuste e 0,5 indica um ajuste apenas ao acaso. Na Tabela 6 são apresentadas as variáveis dependentes e independentes, a estatística ROC e as equações de regressão obtidas para cada classe informacional de vegetação.

Tabela 6 – Resumo dos parâmetros da RLB. Para cada classe informacional são apresentadas as variáveis dependentes e independentes, suas respectivas equações de regressão e estatística ROC.

| Imagens de variáveis dependentes | Imagens de variáveis independentes | ROC | Equação de regressão logística |
|----------------------------------|------------------------------------|--------|---|
| Floresta nativa (FN) | MDEHC, MDD, MDN, MDL e NDVI | 0,9222 | logit (FN)= -18.0747 + 0.003371* MDEHC + 0.000914*MDD + 0.023855* MFN - 0.248674*MFL + 13.965938*NDVI |
| Floresta plantada (FP) | MDEHC, MDD, MDN e MDL | 0,6280 | logit (FP)= -8.1053 + 0.001791* MDEHC - 0.012979*MDD + 0.224121*MFN - 0.087091*MFL |
| Cerrado (CE) | MDEHC, MDD, MDN, MDL e NDVI | 0,7206 | logit (CE)= -6.3016 - 0.001201*MDEHC + 0.018337*MDD+ 0.111852*MFN + 0.121372*MFL + 3.458885*NDVI |
| Campo cerrado (CC) | MDEHC, MDD, MDN e MDL | 0,9129 | logit (CC) = -11.7182 + 0.006901* MDEHC + 0.005408*MDD+ 0.078037*MFN + 0.036867*MFL |
| Campo plantado (CP) | MDEHC e MDD | 0,7113 | logit (CP)= -4.7426 - 0.000696* MDEHC - 0.054048*MDD |

Analisando os valores exibidos na Tabela 6 nota-se que, apesar da disponibilidade, nem todas as variáveis independentes foram utilizadas para determinar a equação de ajuste de todas as classes. Como o parâmetro ROC foi utilizado para avaliar a qualidade da regressão, fundamentou-se no seu valor para auxiliar na tomada de decisão acerca de quais variáveis independentes seriam efetivamente empregadas na análise. Desse modo, pode-se notar que para as classes FP e CE o melhor ajuste (maior valor ROC) ocorreu considerando todas as cinco variáveis de ambiente. No entanto, o mesmo não ocorreu com as classes FP e CC, cujos ajustes não contaram com os valores da variável de ambiente espectral NDVI. Ou seja, para as classes FP e CC, o ajuste com as quatro variáveis de ambiente topográficas (MDEHC, MDD, MDN e MDL) forneceu um melhor valor ROC do que ao se considerar a variável de ambiente espectral NDVI. A classe CP ofereceu seu melhor ajuste com apenas duas variáveis de ambiente topográficas, MDEHC e MDD. Foi verificado também que o melhor ajuste ocorreu com as classes FN e CC, seguidas por CE e CP. O pior resultado de ajuste ocorreu com a classe FP. Esses resultados indicam que a quantidade de variáveis independentes utilizadas na operação não está diretamente relacionada à qualidade dos resultados obtidos pela RLB.

Em termos gerais observa-se que, para o caso analisado, as variáveis independentes MDEHC e MDD foram utilizadas em todos os procedimentos de RLB, sendo, portanto, mais capazes de discriminar as diferenças entre classes analisadas. Destaca-se ainda que para todas as classes de informação, as cinco variáveis independentes eleitas como informações contextuais foram assim consideradas com base no conhecimento especialista, sendo aptas à análise por sua relevância ao tema vegetação. Porém, nem todas variáveis foram utilizadas para todos os casos porque se buscou auxílio no procedimento estatístico ROC, para melhor explorar o seu uso.

Os resultados das RLBs foram parte apresentados em imagens, com valores de probabilidades e imagens de resíduos para as variáveis dependentes (classes informacionais de vegetação) floresta nativa (Figura 15); floresta plantada (Figura 16); cerrado (Figura 17); campo cerrado (Figura 18); e campo plantado (Figura 19). Em todas as imagens, cores frias em tons azuis representam os menores valores, e cores quentes em tons avermelhados representam os maiores valores. Parte dos resultados foi apresentada em forma de relatório, divulgando os valores do parâmetro ROC e também as respectivas equações de regressão.







Figura 15 – Imagens resultantes da RLB, que apresentam valores de probabilidades no intervalo de 0 a 1 em (a) e valores de resíduos no intervalo de -1 a 1 em (b), referentes a floresta nativa.




(a)




(b)

Figura 16 - Imagens resultantes da RLB referente a floresta plantada, apresentando valores de probabilidades estimadas na escala de 0 a 1 em (a) e valores de resíduos de -1 a 1 em (b).



(a)



(b)

Figura 17 – Imagens resultantes da análise de RLB referente a classe cerrado, apresentando valores de probabilidade no intervalo de 0 a 1 em (a) e valores de resíduos entre -1 e 1 em (b).







Figura 18 - Imagens resultantes da RLB da classe campo cerrado, com valores de probabilidades em (a) escalonados de 0 a 1, e, valores de resíduos em (b) escalonados de -1 a 1.



(a)



(b)

Figura 19 - Imagens de valores estimados de probabilidade, no intervalo de 0 a 1 em (a) e seus resíduos no intervalo de -1 a 1 em (b), resultantes da análise de RLB para a classe campo plantado.

Observando a seqüência de ilustrações apresentadas nas Figuras de 15 a 19 pode-se verificar que as imagens de resíduos para todas as classes, apresentadas em (b), exibiram valores inversamente proporcional às imagens de probabilidades estimadas em (a). Notou-se ainda que algumas classes informacionais foram definidas a partir de variáveis de ambiente topográficas e espectrais, outras, apenas com as variáveis de ambiente topográficas e uma delas utilizou somente duas topográficas, o que evidencia a flexibilidade do método para compor os contextos particulares. Para definir quais variáveis de ambiente deveriam ser utilizadas na RLB, observou-se o parâmetro estatístico ROC. Nesses casos, simulações com a combinação de variáveis permitiram constatar qual cenário contribuiria mais para o ajuste e, portanto, quais variáveis deveriam ser consideradas para aquela determinada classe.

As imagens geradas pela RBL foram utilizadas como probabilidades para cada classe informacional de vegetação, aplicando-se a Equação (17) em uma abordagem pixel a pixel, permitindo gerar uma imagem fundamentada em valores de probabilidades particular para cada classe. A metodologia possibilitou a consideração do conhecimento em dois momentos fundamentais: na escolha da informação contextual e na expressão de sua opinião particular sobre a forma da distribuição *a posteriori*, através da indexação dos hiperparâmetros empiricamente.

As imagens fundamentadas em valores de probabilidades de cada classe, geradas pelo modelo probabilístico Bayesiano, foram utilizadas como probabilidades iniciais (ou *a priori*) pelo método de Classificação da Máxima Verossimilhança (CMV). Os resultados foram comparados com o método de CMV convencional com distribuição uniforme de valores de probabilidades *a priori*.

Para facilitar o entendimento, é apresentado na ilustração da Figura 20, um esquema geral das etapas abordadas no processo para introdução de informações contextuais como metodologia para classificação de imagens de sensoriamento remoto. Em síntese, a ilustração da Figura 20 exhibe que: a partir da definição das classes informacionais e seus respectivos contextos, dois caminhos podem ser seguidos. No caminho da modelagem direta (à esquerda), são realizados os procedimentos para se obter imagens booleanas que representam as informações contextuais sobre a classe. Em seqüência são aplicadas operações de intersecção com tais informações contextuais, para se obter a imagem temática resultante de uma classe informacional específica. No caminho da modelagem indireta (à direita), inspeciona-se as bandas espectrais colecionando amostras de treinamento das classes definidas e realiza-se uma operação

de regressão logística binomial com as informações contextuais levantadas. Em seguida, avalia-se a qualidade da regressão, caso o resultado não seja satisfatório, realiza-se nova operação com outra composição de informações contextuais até que se obtenha um ajuste de boa qualidade. Uma vez obtidos os parâmetros de ajuste da regressão, produz-se a imagem de valores estimados de cada classe e utiliza-se essa imagem no modelo probabilístico Bayesiano (Equação (17)), informando empiricamente opinião sobre a distribuição de valores da classe através dos hiperparâmetros α e β , representado respectivamente, posição e dispersão da distribuição. Se o resultando dos valores estimados não for satisfatório conforme a opinião do analista, deve-se informar novos valores de α e β , e verificar os resultados, até se encontrar um cenário adequado à realidade. Ao se chegar a um resultado satisfatório, utiliza-se as imagens fundamentas em valores de probabilidade geradas como valores de probabilidade iniciais na regra de decisão, como o método de CMV, para produção da imagem temática.




Figura 20 – Esquema geral do método de introdução de informações contextuais no processo de classificação de imagens de sensoriamento remoto.

A ilustração da Figura 21 exibe com maior detalhe as etapas envolvidas na classificação contextual por modelagem indireta, em comparação com a metodologia convencional, utilizando a mesmos iniciais de assinaturas espectrais das classes e mesma regra de decisão (CMV). Esta abordagem comparativa teve o intuito de evidenciar a diferença que o conhecimento especialista, introduzido através de informações contextuais, pode provocar no processo de classificação. Após a validação de ambos os métodos de classificação, contextual e convencional, observa-se o resultado e utiliza-se o método que ofereceu melhor desempenho para rotular a imagem temática.




Figura 21 – Ilustração das etapas da metodologia de classificação contextual por modelagem indireta do contexto.

4. RESULTADOS E DISCUSSÃO.

A apresentação dos resultados foi organizada para exibir primeiramente as imagens obtidas pela modelagem do contexto, direta e indireta, em seguida exibindo as imagens temáticas classificadas pela estratégia da Máxima Verossimilhança.

4.1 Modelagem direta.

Aplicando-se a Equação (20) nos PIs de vegetação e quadras editadas obteve-se o resultado ilustrado na Figura 22 que implica na vegetação que ocorre nas quadras e áreas particulares, segundo os critérios adotados. Pela imagem na Figura 22 pode-se verificar que as regiões próximas aos limites do município não foram consideradas. A imagem em detalhe permite verificar que o objetivo de se modelar a vegetação apenas na área das quadras foi alcançado.

Utilizou-se o conhecimento com base na experimentação para definir as áreas de vegetação através do limiar NDVI. Para definir as áreas particulares, o critério adotado pode não ter sido o mais apropriado, no entanto, pelo tamanho e características das áreas, acredita-se que as regiões eliminadas não eram particulares. Portanto, acredita-se que essas áreas foram subestimadas. Porém, em estudos futuros, recomenda-se que se faça a determinação das áreas particulares com informação cadastral do município ou ainda sob a supervisão de alguém capaz de identificá-las.




Figura 22 – Imagem de áreas de vegetação em quadras (quintais - fundos de lote de áreas assumidas particulares).

O resultado verificado na ilustração da Figura 23 foi obtido aplicando-se a Equação (21), na qual a imagem produzida representa a vegetação presente nas vias. O tipo de vegetação das vias são as árvores plantadas nas calçadas e nas ilhas das avenidas. A abordagem empregada na obtenção dessas áreas envolveu algumas operações a mais, como as de distância aritméticas, antes de realizar a operação lógica (Equação (21)). No entanto, não apresentou nível de dificuldade na sua aplicação.




Figura 23 – Imagem da vegetação que ocorrem em vias.

De maneira geral, pôde-se perceber que a modelagem do contexto por meio direto, através da introdução de informações contextuais externas, foi imprescindível à determinação de classes de categorias que não são distinguíveis apenas pela informação espectral.

4.2 Modelagem indireta.

Embora eficiente e de fácil abordagem, a modelagem direta muitas vezes não é suficiente ou aplicável em situações de complexidade espectral elevada, devido a

características de continuidade das superfícies que compõem a paisagem não serem contempladas. Nesses casos, cada classe que se pretende discriminar deve ser analisada particularmente, considerando seus respectivos contextos, modelados indiretamente. Por esse motivo, as categorias de vegetação foram tratadas individualmente, considerando-se as variáveis ambientais, topográficas e espectrais, condicionantes para representar seu contexto próprio. As classes informacionais não relacionadas aos tipos de vegetação não foram tratadas pela metodologia.

Foram coletadas amostras de treinamento das classes informacionais sob supervisão de técnicos da SMAMA. Essas amostras serviram como referência para avaliar a qualidade dos produtos gerados. A partir delas foi possível continuar a coleção de novas amostras em outros locais, que serviram para extração da assinatura espectral das classes nas imagens orbitais e também para obtenção dos coeficientes da RLB a partir das variáveis de ambiente.

4.2.1 Determinação de imagens fundamentadas em valores de probabilidade.

As imagens de probabilidades obtidas com a RLB foram utilizadas como parâmetro θ na Equação (13) para produção das imagens de probabilidades atualizadas para cada classe. Pode ser verificado que praticamente todos os seus parâmetros encontravam-se disponíveis, visto que y e n eram fixos (1 classe entre 5 possíveis) e α , β representam o conhecimento especialista acerca da concentração da distribuição de valores por sua posição e dispersão, respectivamente. Logo, as probabilidades particulares às classes foram estabelecidas em termos do conhecimento empírico do analista, expresso através dos hiperparâmetros α e β , e da função de verossimilhança estabelecida para os dados. A única restrição para valores desses hiperparâmetros foi a de serem escalonados no intervalo de 0 a 1, ou seja, haviam infinitas possibilidades. Como pode ser observado na forma geral do modelo binomial com distribuição *a priori* beta (Equação (13)), os valores informados pelo analista para os hiperparâmetros definem seu grau de influência na distribuição *a posteriori*. Valores muito próximos a 1 para α e β indicam que o analista não quer se expressar, deixando a função de verossimilhança dominar completamente a distribuição, enquanto valores próximos a 0 indicam que sua opinião desempenhou forte influência na distribuição *a posteriori*.

Os valores de α e β utilizados para cada classe informacional de vegetação são apresentados na Tabela 7. Para se chegar a esses valores foram realizadas várias simulações e, conseqüentemente, verificações dos resultados, num processo iterativo em busca de um cenário mais próximo à realidade. Tratou-se, pois, de um processo oneroso. Principalmente no início. Entretanto, após algumas simulações se tornou mais ágil, devido provavelmente a uma maior noção acerca da real sensibilidade do modelo, por parte do analista. A partir dos valores estabelecidos foram produzidas as imagens de probabilidades *a posteriori*, para cada classe informacional. Essas imagens podem ser observadas na seqüência de ilustrações apresentadas nas Figuras 24, 25, 26, 27 e 28.

Tabela 7 – Valores empíricos dos hiperparâmetros α e β (*a priori*) informados para cada classe na produção das imagens fundamentadas em valores de probabilidade *a posteriori*.

| Classes informacionais | Hiperparâmetros | |
|------------------------|-----------------|---------|
| | α | β |
| Floresta nativa (FN) | 0,34 | 0,20 |
| Floresta plantada (FP) | 0,30 | 0,70 |
| Cerrado (CE) | 0,26 | 0,60 |
| Campo cerrado (CC) | 0,31 | 0,20 |
| Campo plantado (CP) | 0,18 | 0,22 |




Figura 24 – Imagem fundamentada em valores de probabilidade, determinadas pelo modelo probabilístico Bayesiano para a classe de vegetação floresta nativa.




Figura 25 – Ilustração de imagem fundamentada em valores de probabilidades determinada pelo modelo probabilístico Bayesiano para classe floresta plantada.




Figura 26 - Imagem fundamentada em valores de probabilidade determinadas pela aplicação do modelo probabilístico Bayesiano para a classe de vegetação de cerrado.




Figura 27 - Imagem fundamentada em valores de probabilidade produzida pela aplicação do modelo probabilístico Bayesiano para a classe informacional campo cerrado.




Figura 28 - Imagem fundamentada em valores de probabilidade determinada pela aplicação do modelo probabilístico Bayesiano para a classe de vegetação campo plantado.

Realizando uma leitura nos valores de probabilidade encontrados para cada classe informacional, pôde-se verificar que apresentaram diferentes concentrações de intervalos entre os máximos e mínimos respectivos. Merece destaque a diferença dos intervalos da classe floresta plantada (Figura 25), na qual a concentração foi quase homogênea, expressando pouca capacidade em detectar variação por toda a área. Isto implica em menor contribuição para discriminação da classe e, portanto, ao processo como um todo. Esta classe foi a que apresentou o pior resultado na avaliação da qualidade da RLB. A partir dessa constatação, pode-se argumentar que, apesar da flexibilidade do modelo beta-binomial, a qualidade do seu produto está fortemente relacionada ao resultado da RLB, portanto, deve-se direcionar atenção especial aos resultados de avaliação da qualidade da regressão.

Uma vez com as imagens fundamentadas em valores de probabilidades *a posteriori* produzidas para cada classe informacional, utilizou-se seus valores como probabilidades iniciais no processo de CMV.

4.2.2 Validação do método e classificação da imagem.

Dois procedimentos de Classificação pela Máxima Verossimilhança foram avaliados neste trabalho. O primeiro, pelo método de Classificação Tradicional, que serviu como padrão (ou referência) para avaliar o modelo Contextual proposto, por comparação. O segundo procedimento adotado foi pelo método de Classificação Contextual por Modelagem Indireta do Contexto. Ambos os procedimentos foram validados pelas respectivas matrizes de erro e coeficiente *Kappa*, e posteriormente comparados. Classificou-se a imagem pelo método que apresentou o melhor resultado.

As matrizes de erro referentes às metodologias avaliadas podem ser acessadas no Apêndice C. A matriz de erro resultante pelo método de Classificação Tradicional encontra-se no Apêndice C1. A matriz de erro obtida do método Classificação Contextual encontra-se no Apêndice C2. Os valores de coeficiente *Kappa* e sua variância, derivados das matrizes de erro, estão apresentados na Tabela 8. As matrizes de erro constantes nos Apêndices mostram ainda os erros de omissão²² e comissão²³ por classe. Tanto no valor do coeficiente *Kappa* estimado quanto nos erros de omissão e comissão, o método de Classificação Contextual apresentou melhor desempenho geral.

Para saber, entretanto, se os métodos avaliados apresentavam diferença estatística significativa entre si, foram calculados os valores *Z* entre os métodos através da Equação (6). Esses valores *Z* estão apresentados na parte sombreada de cor cinza, dispostos em forma de matriz de significância, na Tabela 8. Considerando os valores exibidos, pode-se constatar que, pelo teste estatístico *Z* bilateral, avaliado ao nível de confiança de 95%, H_0 deve ser rejeitada. Houve, pois, diferença significativa entre os valores de coeficiente *Kappa* estimados e, portanto, entre métodos de Classificação Tradicional e Classificação Contextual comparados.

²² Erros de omissão referem-se a pixels que foram omitidos de sua verdadeira classe e rotulados a uma outra classe.

²³ Erros de comissão fazem referência a pixels que foram incorretamente rotulados a uma classe específica quando pertencem a outra.

Tabela 8 – Matriz de significância de valores Z calculados para os métodos de Classificação Tradicional e Contextual, bem como seus respectivos valores de coeficientes *Kappa* e variâncias.

| Métodos de Classificação | Convencional | Contextual |
|---------------------------|-----------------|-------------|
| <i>Kappa</i> | 0,8528 | 0,9199 |
| Variância do <i>Kappa</i> | 0,00000013 | 0,000000076 |
| Convencional | 2635,242 | - |
| Contextual | 1835,098 | 72,185 |

Pelos valores de coeficiente *Kappa* apresentados na Tabela 8 e sua diferença estatística observada, constatou-se que o método de Classificação Contextual foi superior na avaliação em mais de 6,5%, em relação ao método de Classificação Tradicional. Ou seja, uma vez comprovada a diferença entre os métodos, aquele que apresentou melhor resultado pelo coeficiente *Kappa* foi considerado superior. Desse modo, empregou-se o método de Classificação Contextual para produzir a imagem temática apresentada na ilustração da Figura 29.

A carta-imagem de vegetação apresentada na ilustração da Figura 29 exibe algumas características especiais que merecem ser comentadas. A primeira é referente ao número de classes informacionais presentes. Ao observar as categorias de legenda da imagem temática, pode-se notar a presença de duas classes informacionais que não constam na relação inicialmente apresentada (Tabela 1). A cobertura por nuvens está presente nas imagens “C”, “D” e “E”, como pode ser observado na ilustração da Figura 7, ou nos dados tabulares exibidos na Tabela 2. Uma vez que nuvens produzem sombra, toda porção de área coberta por nuvens exibe área equivalente de sombra. Logo, a inclusão dessas classes foi necessária para evitar confusão com as demais, visto que sombra foi confundida com recursos hídricos (provavelmente devido a pouca disponibilidade de bandas espectrais do produto *QuickBird*). Outra característica especial da carta-imagem de vegetação refere-se à sua aparência não uniforme nas áreas de intersecção, onde as imagens originais foram concatenadas (principalmente entre as imagens “A” e “E”, “B” e “C”, “B” e “D”). Tal aspecto se deve à existência de um diferencial radiométrico entre as imagens, provavelmente devido à variação temporal de aquisição das imagens, uma vez que representam um período de intervalo entre outubro

de 2005 e julho de 2006. Nota-se ainda que, devido à proximidade de respostas espectrais, a classe solo exposto aparece como ruído por toda imagem, provavelmente devido sua confusão com os telhados de cerâmica de edificações.




Figura 29 – Imagem de classes temáticas de vegetação obtida por processo de CMV através da introdução de Informações Contextuais (Classificação Contextual).

4.2.3 Quantificação de área das classes informacionais.

Após a determinação das classes informacionais, pela modelagem direta e indireta do contexto, quantificou-se suas respectivas áreas. Os resultados podem ser observados nos valores dados em hectares, apresentados na Tabela 9. Observando-se os valores de

área permeável (em negrito), pode-se perceber a diferença, cerca de 880 ha, quando determinado pelo processo de modelagem indireta (como a soma de áreas das classes de vegetação), de quando determinado pelo processo de modelagem direta (a partir de valores de NDVI). Essa diferença foi verificada pela consideração das classes nuvens e sombra, contempladas apenas no processo de modelagem indireta. Ressalta-se que as classes recursos hídricos e solo exposto não foram contabilizadas na soma da classe área permeáveis. Nota-se ainda que, devido à confusão da classe solo exposto com a classe área impermeável (devido ao telhado das edificações), o valor de solo exposto pode ter sido superestimado.

Tabela 9 – Áreas das classes informacionais obtidas por modelagem direta e indireta (carta-imagem temática) do contexto, expressas em hectares.

| Classe informacional | Área (ha) | |
|------------------------|------------------|--------------------|
| | Modelagem direta | Modelagem Indireta |
| Área permeável | 14.242,3 | 13.362,2 |
| Vegetação em vias | 1.497,5 | - |
| Vegetação em quintais | 8.118,7 | - |
| Floresta nativa | - | 1.352,4 |
| Floresta plantada | - | 746,1 |
| Cerrado | - | 3.582,4 |
| Campo cerrado | - | 2.563,1 |
| Campo plantado | - | 5.118,2 |
| Solo exposto | - | 1.296,6 |
| Recursos hídricos | - | 188,2 |
| Nuvens | - | 629,8 |
| Sombra | - | 691,4 |
| Área impermeável total | - | 16.965,0 |
| Área total das classes | - | 33.133,2 |

4.2.4 Pós-classificação.

Observando o melhor resultado da classificação apresentado na Figura 29, verificaram-se ruídos de algumas classes por toda a área. Esse efeito é típico da abordagem de classificação por pixel, e não é desejável para fins qualitativos de visualização, onde a aparência é importante. No entanto, conforme expõe Mather (1999), quando um pixel central é atribuído a uma classe, cujos vizinhos imediatos são assinalados a uma outra classe, diferente da sua, provavelmente esse pixel pertence à classe de seus vizinhos, e por isso pode ser rotulado novamente para poder se adequar. Vieira (2000) sugere técnicas de refinamento da classificação por meio de filtros da moda ou da mediana para reduzir esse efeito.

Para apresentação do resultado da classificação na forma de carta-imagem à SMAMA, foram sugeridas três opções de refinamento da imagem temática produzida. Tais opções foram geradas pelo filtro da moda, que emprega o valor mais freqüente da proximidade imediata (superior, inferior, esquerda, direita e diagonais) do pixel para atualizar seu valor. As opções diferenciaram-se apenas pelo tamanho da janela-móvel, que definiu a vizinhança considerada para amostragem de valores. As imagens produzidas pelo referido filtro, com as dimensões das janelas-móveis de 3x3, 5x5 e 7x7, estão apresentadas nos Apêndices D1, D2 e D3, respectivamente. Constatou-se que o melhor resultado visual foi obtido pelo filtro com janela-móvel de dimensão 7x7.

5. CONCLUSÃO

Diante dos resultados, pode-se constatar que os objetivos foram alcançados, pois foi possível produzir uma carta-imagem das categorias temáticas de vegetação do Município de Belo Horizonte – MG. A metodologia proposta para modelagem do contexto, direta e indireta, permitiu empregar informações contextuais para melhor discriminar as classes informacionais almejadas.

Para avaliar a eficácia da metodologia proposta, optou-se por compará-la à metodologia de classificação tradicional pelo Classificador da Máxima Verossimilhança. Com este intuito, empregou-se como referência, pixels purificados extraídos das amostras de treinamento, determinados pela distância de *Mahalanobis* com o valor para o critério de semelhança arbitrado em 50%. A avaliação dos processos de Classificação, Contextual e Tradicional, foi realizada pela obtenção das matrizes de contingência de cada método, das quais foi possível derivar os valores de coeficiente *Kappa*. Tais valores indicaram a superioridade da Classificação Contextual ($Kappa = 0,9199$) em relação à Classificação Tradicional ($Kappa = 0,8528$). Para constatar que a indicação de superioridade foi, contudo, verídica, aplicou-se o teste estatístico *Z* bilateral ao nível de significância de 5% aos valores do coeficiente *Kappa* obtidos. Verificou-se com o teste *Z* que, ao nível de confiança de 95%, a hipótese de nulidade referente à igualdade entre os valores *Kappa* foi rejeitada. Portanto, ficou comprovada a diferença estatística significativa entre os métodos, o que permite afirmar a superioridade de cerca de 6,5% do processo de Classificação Contextual.

Recursos da Inferência Bayesiana mostraram-se adequados à modelagem de Informações Contextuais no processo de classificação de imagens para áreas urbanas. Embora a classificação tenha sido automática, o papel do analista na etapa de introdução de Informações Contextuais foi fundamental para agregar conhecimento ao processo. Esta etapa contou com a opinião do analista acerca da indexação da distribuição através dos hiperparâmetros α e β , determinados por simulações e análises sucessivas dos resultados, realizadas iterativamente até a obtenção de um cenário mais representativo sobre a realidade de cada classe. Desse modo, as imagens fundamentadas em valores de probabilidade determinadas pelo modelo Bayesiano foram embasadas em informações do ambiente e na opinião pessoal do analista. Percebeu-se com isso que o modelo probabilístico produzido pela Inferência Bayesiana pode ser estendido a aplicações de análises espaciais que requeiram imagens fundamentadas em valores de probabilidades

baseadas em conhecimento. O desempenho verificado pela metodologia pode ser considerado satisfatório, uma vez que foi aplicado em cenário urbano (reconhecidamente mais complexo), obtendo-se uma representação compatível com a realidade. Embora se acredite que o desempenho da metodologia seja superior para aplicações de classificação em áreas com características mais homogêneas (como culturas agrícolas, por exemplo).

Em relação às dificuldades encontradas, merecem menção: a inconsistência dos dados vetoriais fornecidos; as estratégias usadas para ortorretificar a imagem “E” (Figura 7 – Imagens Padrão *QuickBird* multiespectrais que definem a área de estudo (Município de Belo Horizonte-MG), em composição de cores naturais (bandas 1, 2 e 3 nas cores azul, verde e vermelha, respectivamente), dispostas em diferentes escalas para melhor apresentação. Figura 7); as operações para correção do efeito de borda que definiu nova área de estudo; a aplicação do paradigma Bayesiano na modelagem espacial; e a correção radiométrica das imagens (atenuação atmosférica) devido provavelmente às diferenças nas datas de aquisição.

Para o desenvolvimento de trabalhos futuros recomenda-se utilizar área maior que o limite de interesse, com vistas a minimizar os problemas causados pelo efeito de borda. Apesar dos diversos fatores que podem interferir na radiometria dos pixels, recomenda-se o planejamento para aquisição de imagens com menor intervalo de tempo entre datas de tomada das imagens, pois, em relação ao tempo, parte da interferência pode ser devido aos efeitos atmosféricos, parte devido à alteração na estrutura da própria planta. Sugere-se ainda a materialização de marcos geodésicos, em locais despovoados, com intuito de apoiar o georreferenciamento de imagens (como a imagem “E”, por exemplo).

Aponta-se que algumas linhas de investigação promissoras para continuação deste trabalho seriam: a utilização do modelo Bayesiano como regra de decisão; a introdução da correlação espacial entre os pixels com vistas a ganho de desempenho da metodologia; a exploração de métodos de avaliação prévia da qualidade do modelo Bayesiano; a utilização de outras famílias de distribuição conjugada (como a normal multivariada, por exemplo) para determinação de parâmetros contínuos; e a aplicação do modelo Bayesiano com outras regras de decisão, não paramétricas como as Redes Neurais Artificiais.

6. REFERÊNCIAS

ABKAR, A. A.; MOHAMMED, A. S.; MULDER, N. J. **Likelihood-based image segmentation and classification: a framework for the integration of expert knowledge in image classification procedures.** International Journal of Applied Earth Observation and Geoinformation, v.2, n.2. 2000. p.104-119.

AGUILAR, F. J. *et al.* **The accuracy of grid digital elevation models linearly constructed from scattered sample data.** International Journal of Geographical Information Science, v.20, n.2. 2006. p.169-192.

ALESHEIKH, A. A.; FARD, F. S. N; TALEBZADEH, A. Improving classification accuracy using knowledge based approach. In: Map India Conference, 2003. **Proceedings...** Disponível em: <<http://www.gisdevelopment.net/technology/ip/pdf/58.pdf>>. Acesso em: 5 maio 2008.

ANTUNES, M. H. **6S code adapted for atmospheric corrections of remotely sensed images in raw format of 8 bits.** 2001. Disponível em <<http://www.ltid.inpe.br/dsr/mauro/6s/>>. Acesso em 5 maio 2008.

BALTSAVIAS, E. P. **Object extraction and revision by image analysis using existing geodata and knowledge: current status and steps towards operational systems.** ISPRS Journal of Photogrammetry & Remote Sensing, v. 58, 2004. p.129-151.

BAYES, T. **An essay towards solving a problem in the doctrine of chances.** Philosophical Transactions of the Royal Society. 1764. Disponível em <<http://www.stat.ucla.edu/history/essay.pdf>>. Acesso em: 5 maio 2008.

BENZ, U. C. *et al.* **Multi-resolution object-oriented fuzzy analysis of remote sensing data for GIS-ready information.** ISPRS Journal of Photogrammetry & Remote Sensing, v.58. 2004. p.239-258.

BRAGA, A. L. **Identificação de extensas áreas de culturas agrícolas numa abordagem espectro-temporal utilizando imagens MODIS.** 2007. 124 p. Dissertação (Mestrado em Informações Espaciais) – Universidade Federal de Viçosa, Viçosa. 2007.

CAYUELA, L *et al.* **Classification of a complex landscape using Dempster-Shafer theory of evidence.** International Journal of Remote Sensing, v. 27, 2006. p.1951-1971.

CHAGAS, C. S. **Mapeamento digital de solos por correlação ambiental e redes neurais em uma bacia hidrográfica no domínio de Mar de Morros.** 2006. 223 p. Tese (Doutorado em Solos) – Universidade Federal de Viçosa, Viçosa. 2006.

CHANUSSOT, J.; BENEDIKTSSON, J. A.; FAUVEL, M. **Classification of remote sensing images from urban areas using a fuzzy possibilistic model.** IEEE Geoscience and Remote Sensing Letters, v.3, n.1. 2006. p.40-44.

CHAVES, M. A. **Modelos digitais de elevação hidrologicamente consistentes para a Bacia Amazônica**. 2002. 115 p. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa. 2002.

CLARK LABS. **IDRISI Andes edition**. Worchester, 2006. Clark University. Programa de Computador: 1 CD-ROM.

CONGALTON, R. G. **A review of assessing the accuracy of classifications of remotely sensed data**. Remote Sensing of Environment, v. 37. 1991. p.35-46.

DANIELS, A. E. **Incorporating domain knowledge and spatial relationships into land cover classifications: a rule based approach**. International Journal of Remote Sensing, v.27, n.14. 2006. p.2949-2975.

De JONG, S. M.; HORNSTRA, T.; MAAS, H. **An integrated spatial and spectral approach to the classification of Mediterranean land cover types: the SSC method**. International Journal of Applied Earth Observation and Geoinformation, v.3, n.2. 2001. p 176-183.

DIGITALGLOBE. **QuickBird Digital Products** – Product Guide. 2007. Disponível em www.digitalglobe.com/digitalglobe2/file.php/511/QuickBird_Imagery_Products-Product_Guide.pdf. Acessado em: 5 maio 2008

DOMAÇ, A.; SÜZEN, M. L. **Integration of environmental variables with satellite images in regional scale vegetation classification**. International Journal of Remote Sensing, v.27, n.7. 2006. p.1329-1350.

EASTMAN, J. R. **IDRISI Andes tutorial**. Worcester: Clark University. 2006. 284p.

EDWARDS, W.; LINDMAN, H.; SAVAGE, L. J. **Bayesian statistical inference for psychological research**. In: POLSON, N. G.; TIAO, G. C. (Org.). Bayesian inference. The International Library of Critical Writings in Econometrics, v.7. Cambridge: University Press, 1995. p. 140-189. ISBN 1-85278-668.

EIUMNOH, A.; SHRESTHA, R. P. Can DEM enhance the digital image classification? 1997. In: Asian Conference on Remote Sensing. **Proceedings...** Disponível em: <http://www.gisdevelopment.net/aars/acrs/1997/ts9/ts9007.asp>. Acesso em: 5 maio 2008.

ESRI - ENVIRONMENTAL SYSTEM RESEARCH INSTITUTE. **ARC/INFO v.7.1.1**. Redlands, 1997. Programa de computador. 2 CD-ROM.

FRASER, C. S.; DIAL, G.; GRODECKI, J. **Sensor orientation via RPCs**. Journal of Photogrammetry & Remote Sensing, v. 60, 2006. p.182-194.

FRITZ, S.; SEE, L. **Comparison of land cover maps using fuzzy agreement**. International Journal of Geographical Information Science, v.19, n.7. 2005. p. 787-807.

GELMAN, A. *et al.* **Bayesian data analysis**. 1st. Ed. London: Chapman & Hall, 1995. 526 p. ISBN 0-412-03991-5.

GONÇALVES, R. P. *et al.* Determinação da precisão posicional na transformação de coordenadas entre sistemas de referência terrestre. In: XI CONEA, 2007a. **Anais...** São Paulo-SP.

GONÇALVES, R. P.; ASSIS, L. C.; VIEIRA, C. A. O. Comparison of sampling methods to classification of remotely sensed images. In: IV SIAP, 2007b. **Anais...** Viçosa-MG.

GRUIJTER, J. **Spatial sampling schemes for remote sensing**. In: A. STEIN *et. al.* (Org.), *Spatial statistics for remote sensing*. Netherlands: Kluwer Academic Publishers, 1999. p 57-81. ISBN 0-7923-5978-X.

HOUAISS, A. (Ed.). **Dicionário Houaiss da língua portuguesa**. 2001. Rio de Janeiro: Objetiva.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Cidades@**. 2007. Disponível em <<http://www.ibge.gov.br/cidadesat/default.php>>. Acesso em: 5 maio 2008.

JACOBSEN, K. **Geometry of satellite images** – calibration and mathematical models. In: Korean Society of Remote Sensing (Hrsg.): ISPRS international conference. Jeju, 2005. p.182-185. Disponível em: <www.ipi.uni-hannover.de/uploads/tx_tkpublikationen/GeomSatJac.pdf>. Acesso em: 5 maio 2008.

LAHA, A.; PAL, N. R.; DAS, J. **Land cover classification using fuzzy rules and aggregation of contextual information through evidence theory**. IEEE Transactions on Geoscience and Remote Sensing, v. 44, n.6. 2006.

LEE, P. M. **Bayesian statistics: an introduction**. 2nd. Ed. New York: John Wiley & Sons, 1997. 344 p. ISBN 0-471-19481-6.

LEICA GEOSYSTEMS GEOSPATIAL IMAGING. **ERDAS IMAGINE 9.1**. On-Line Help. 2006. Programa de computador. 1 CD-ROM.

LIANG, S. **Quantitative remote sensing of land surfaces**. 1st Ed. Hoboken: John Wiley & Sons, 2004. 534 p. ISBN 0-471-28166-2.

LIEDTKE, J. **QuickBird2 system description and product overview**. Presentation in JACIE Workshop. Washington D.C. 2002. Disponível em: <ldcm.nasa.gov/library/HSRCIW02/QuickBird2_Overview_Liedtk.pdf>. Acesso em: 5 maio 2008.

MALPICA, J. A.; ALONSO, M. C.; SANZ, M. A. **Dempster-Shafer theory in geographic information systems: a survey**. Expert Systems with Applications, v. 32, 2007. p. 47-55.

MAROTTA, G. S. *et al.* Correção geométrica em imagens de alta resolução utilizando transformação geométrica, propagação de variâncias e método dos mínimos quadrados. In: XXIII Congresso Brasileiro de Cartografia, 2007. p.1319-1328. **Anais...** Rio de Janeiro.

MATHER, P. M. **Computer processing of remotely-sensed images: an introduction.** 3rd. Ed. Chichester: John Wiley & Sons, 2004. 324 p. ISBN 0-470-84919-3.

MATHER, P. M. **Land cover classification revisited.** In: Advances in Remote Sensing and GIS Analysis. P. M. Atkinson and N. J. Tate, eds. Chichester: Wiley & Sons. 1999. pp. 7-16.

MELGANI, F. **Contextual reconstruction of cloud-contaminated multitemporal multispectral images.** IEEE Transactions on Geosciences and Remote Sensing, v.44, n.2. 2006. p.442-455.

MELGANI, F.; BAZI, Y. **Markovian fusion approach to robust unsupervised change detection in remotely sensed imagery.** IEEE Geoscience and Remote Sensing Letters. v.3, n.4. 2006. p.457-461.

MELGANI, F.; SERPICO, S. B. **A statistical approach to the fusion of spectral and spatio-temporal contextual information for the classification of remote sensing images.** Pattern Recognition Letters, v.23. 2002. p.1053-1061.

MELLO, M. P. *et al.* Redes bayesianas no delineamento de culturas agrícolas usando informações contextuais. In: XXIII Congresso Brasileiro de Cartografia, 2007. p.1289-1295. **Anais...** Rio de Janeiro.

MONICO, J. F. G. **Posicionamento pelo NAVSTAR-GPS: descrição, fundamentos e aplicações.** São Paulo: Ed. UNESP, 2000. 287 p. ISBN 85-7139-328-1.

NAHAS, M. I. P. **Índice de qualidade de vida urbana de Belo Horizonte: experiência de construção e perspectivas de aplicabilidade de um instrumento urbanístico, na gestão da cidade.** 2000. Curso de gestão urbana e de cidades. Belo Horizonte. 2000.

NCAVEO - NETWORK FOR CALIBRATION AND VALIDATION OF EARTH OBSERVATION. **Atmospheric correction.** Example 1. Atmospheric correction of a Landsat TM image. 2005. Disponível em: <www.ncaveo.ac.uk/special_topics/atmospheric_correction/example1/>. Acesso em: 5 maio 2008.

NIU, X. *et al.* Geometric modeling and processing of *QuickBird* stereo imagery. In: XXth ISPRS Congress, 2004. p. 689. **Proceedings...** Istanbul. 2004.

OKEKE, F. I. **Review of digital images orthorectification techniques.** 2006. Disponível em: <http://www.gisdevelopment.net/technology/ip/fio_1.htm>. Acesso em: 5 maio 2008.

PAULINO, C. D.; TURKMAN, M. A. A.; MURTEIRA, B. **Estatística Bayesiana.** Lisboa: Fundação Calouste Gulbenkian, 2003. 446 p. ISBN 972-31-1043-1.

PELLIZZERI, T. M. *et al.* **Multitemporal/multiband SAR classification of urban areas using spatial analysis: statistical versus neural kernel-based approach.** IEEE Transactions on Geoscience and Remote Sensing, v.41, n.10. 2003. p.2338-2353.

PENA, S. D. **Bayes: o ‘cara’!** Revista Ciência Hoje, v.38, n.228. 2006. p.22-29.

- PINTO, M. L. A. **Relação empírica da visibilidade com profundidade óptica, concentração de aerossóis e focos de queimadas em Alta Floresta e Cuiabá, em 1993 e 1994.** 2001. 141 p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2001.
- PINZ, A. *et al.* **Active fusion** – a new method applied to remote sensing image interpretation. *Pattern Recognition Letters*, v. 17, 1996. p. 1349-1359.
- POLSON, N. G.; TIAO, G. C. **Bayesian inference.** Cambridge: University Press, 1995. *The International Library of Critical Writings in Econometrics*, v. 7. ISBN 1-85278-668.
- PRESS, S. J. **Bayesian statistics: principles, models, and applications.** New York: John Wiley & Sons, Inc, 1989. 237 p. ISBN 0-471-63729-7.
- RAMSEY, F. P. **Truth and probability.** In: POLSON, N. G.; TIAO, G. C. (Org.). *Bayesian inference. The International Library of Critical Writings in Econometrics*, v.7. Cambridge: University Press, 1995. p. 1-43. ISBN 1-85278-668.
- SANTOS, C. A. **Efeito fotoelétrico.** 2003. Disponível em: < <http://www.if.ufrgs.br/einstein/efeitofotoeletricoindex.html>>. Acesso em: 5 maio 2008.
- SAVAGE, L. J. **Elicitation of personal probabilities and expectations.** In: POLSON, N. G.; TIAO, G. C. (Org.). *Bayesian inference. The International Library of Critical Writings in Econometrics*, v.7. Cambridge: University Press, 1995. p. 106-124. ISBN 1-85278-668.
- SHI, W. Z.; TIAN, Y. **A hybrid interpolation method for the refinement of a regular grid digital elevation model.** *International Journal of Geographical Information Science*, v.20, n.1. 2006. p.53-67.
- SKIDMORE, A. K. **Accuracy assessment of spatial information.** In: A. STEIN *et al.* (Org.), *Spatial statistics for remote sensing.* Netherlands: Kluwer Academic Publishers, 1999. p.197-209. ISBN 0-7923-5978-X.
- STUCKENS, J.; COPPIN, P. R.; BAUER, M. E. **Integrating contextual information with per-pixel classification for improved land cover classification.** *Remote Sensing of Environment*, v.71. 2000. p. 282-296.
- TACHIIRI, K. **Calculating NDVI for NOAA/AVHRR data after atmospheric correction for extensive images using 6S code: a case study in the Marsabit District, Kenya.** *ISPRS Journal of Photogrammetry & Remote Sensing*, v.59. 2005. p.103-114.
- TANRÉ, D. *et al.* **Description of a computer code to simulate satellite signal in the solar spectrum: the 5S code.** *International Journal of Remote Sensing*, v.11, 1990. p.659-668.
- TOUTIN, T. **Sensor orientation and ortho-rectification of high resolution satellite images: review and application with FORMOSAT-2.** 2006. Disponível em: <http://www.gisdevelopment.net/technology/ip/thi_1.htm>. Acesso em: 5 maio 2008.

- VERMOTE, E. *et al.* **Second simulation of the satellite signal in the solar spectrum (6S): an overview.** IEEE Transactions on Geoscience and Remote Sensing, v.35, n.3, 1997a. p.675-686.
- VERMOTE, E. *et al.* **Second simulation of the satellite signal in the solar spectrum (6S).** 6S User Guide Version 2. 1997b. 54 p.
- VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações.** Viçosa, UFV: Imprensa Universitária, 1991. 449 p.
- VIEIRA, C. A. O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study.** 2000. 327 p. Thesis (Doctor of Philosophy in Physical Geography) - University of Nottingham, Nottingham. 2000.
- WU, J.; WANG, D.; BAUER, M. E. **Image-based atmospheric correction of QuickBird imagery of Minnesota cropland.** Remote Sensing of Environment, v.99. 2005. p.315-325.
- YASHON, O. O.; NGIGI, T. G.; TATEISHI, R. **On the optimization and selection of wavelet texture for feature extraction from high-resolution satellite imagery with application towards urban-tree delineation.** International Journal of Remote Sensing, v.27, n.1, 2006. p.73–104. ISSN 0143-1161.
- ZHU, C. *et al.* **Estimation of average DEM accuracy under linear interpolation considering random error at the nodes of TIN model.** International Journal of Remote Sensing, v.26, n.24. 2005. p.5509-5523.
- ZHU, L.; TATEISHI, R. **Fusion of multisensor multitemporal satellite data for land cover mapping.** International Journal of Remote Sensing, v.27, n.5. 2006. p. 903-918.

APÊNDICE A

Parâmetros utilizados no processo de ortorretificação das imagens com emprego do modelo RPC.

A 1. Parâmetros de 122 pontos de controle utilizados na imagem “A”.

| ID do GCP | X (entrada) | Y (entrada) | X (referência) | Y (referência) | Z (referência) | RMS | Contribuição |
|------------------|--------------------|--------------------|-----------------------|-----------------------|-----------------------|------------|---------------------|
| #1 | 605906,70 | 7811636,10 | 605961,51 | 7811649,80 | 796 | 1,38 | 1,69 |
| #2 | 607337,70 | 7812050,70 | 607382,78 | 7812083,10 | 862 | 1,47 | 1,81 |
| #4 | 606681,30 | 7811230,50 | 606732,00 | 7811253,03 | 818 | 1,03 | 1,27 |
| #5 | 607590,30 | 7810173,30 | 607643,55 | 7810179,07 | 780 | 0,33 | 0,40 |
| #6 | 606132,30 | 7810089,90 | 606184,06 | 7810099,27 | 783 | 0,87 | 1,07 |
| #7 | 604880,10 | 7810110,30 | 604929,13 | 7810127,93 | 810 | 0,63 | 0,77 |
| #8 | 604466,10 | 7809211,50 | 604516,63 | 7809230,43 | 811 | 0,31 | 0,38 |
| #9 | 605324,10 | 7809642,90 | 605373,10 | 7809660,35 | 811 | 0,63 | 0,78 |
| #10 | 606693,30 | 7809012,30 | 606746,05 | 7809021,93 | 784 | 0,84 | 1,03 |
| #12 | 604284,90 | 7808216,10 | 604333,98 | 7808239,07 | 830 | 0,75 | 0,93 |
| #13 | 606274,50 | 7809524,70 | 606325,68 | 7809542,33 | 807 | 0,62 | 0,76 |
| #14 | 607602,30 | 7809403,50 | 607658,16 | 7809410,26 | 782 | 0,81 | 0,99 |
| #15 | 607311,90 | 7809673,50 | 607364,24 | 7809683,95 | 792 | 0,20 | 0,25 |
| #16 | 607134,90 | 7808421,90 | 607182,71 | 7808443,64 | 828 | 0,84 | 1,03 |
| #17 | 606047,10 | 7808022,30 | 606098,07 | 7808037,88 | 802 | 0,55 | 0,67 |
| #18 | 605063,70 | 7807856,10 | 605111,78 | 7807881,65 | 837 | 0,65 | 0,79 |
| #19 | 603811,50 | 7807442,70 | 603860,78 | 7807471,39 | 839 | 0,50 | 0,61 |
| #20 | 605442,90 | 7806986,10 | 605491,12 | 7807015,06 | 845 | 0,48 | 0,59 |
| #21 | 607169,10 | 7807467,30 | 607219,24 | 7807483,19 | 806 | 0,64 | 0,79 |
| #22 | 607353,90 | 7806620,70 | 607405,83 | 7806634,02 | 796 | 0,72 | 0,88 |
| #24 | 606647,70 | 7807287,90 | 606700,53 | 7807305,60 | 816 | 1,17 | 1,43 |
| #23 | 607131,90 | 7805571,30 | 607180,47 | 7805596,59 | 827 | 1,03 | 1,26 |
| #25 | 605079,75 | 7805749,89 | 605130,88 | 7805766,87 | 807 | 0,19 | 0,23 |
| #26 | 606611,71 | 7806191,23 | 606664,00 | 7806201,85 | 793 | 0,32 | 0,39 |
| #27 | 603148,37 | 7806716,41 | 603194,26 | 7806756,54 | 868 | 0,89 | 1,09 |
| #28 | 603830,52 | 7806372,86 | 603877,64 | 7806405,86 | 857 | 0,52 | 0,64 |
| #29 | 604401,71 | 7806893,11 | 604449,19 | 7806919,52 | 846 | 1,62 | 1,99 |
| #30 | 604246,38 | 7806045,76 | 604295,20 | 7806074,84 | 844 | 0,47 | 0,58 |
| #32 | 603284,70 | 7806191,48 | 603330,82 | 7806230,51 | 865 | 0,88 | 1,08 |
| #33 | 602758,02 | 7805948,01 | 602804,80 | 7805985,49 | 865 | 0,27 | 0,33 |
| #34 | 603212,45 | 7804953,82 | 603258,33 | 7804982,89 | 844 | 1,06 | 1,30 |
| #35 | 604311,63 | 7804742,42 | 604363,20 | 7804756,41 | 804 | 0,71 | 0,87 |
| #36 | 604830,78 | 7803601,06 | 604883,61 | 7803615,57 | 806 | 1,00 | 1,22 |
| #39 | 603549,44 | 7802355,68 | 603601,70 | 7802375,81 | 817 | 0,55 | 0,67 |
| #40 | 604572,88 | 7802933,31 | 604623,97 | 7802950,73 | 811 | 0,47 | 0,57 |
| #42 | 606708,20 | 7803216,50 | 606760,66 | 7803235,66 | 808 | 0,87 | 1,06 |
| #43 | 606343,16 | 7804399,19 | 606396,49 | 7804412,47 | 804 | 1,10 | 1,35 |
| #46 | 605264,90 | 7801175,60 | 605315,78 | 7801202,94 | 831 | 0,76 | 0,94 |
| #45 | 604832,37 | 7802073,01 | 604884,17 | 7802090,88 | 812 | 0,55 | 0,68 |
| #47 | 603521,85 | 7801269,16 | 603567,98 | 7801305,22 | 859 | 0,46 | 0,57 |

| | | | | | | | |
|------|-----------|------------|-----------|------------|-----|------|------|
| #49 | 604256,86 | 7799576,73 | 604305,32 | 7799604,07 | 835 | 0,49 | 0,60 |
| #50 | 606265,30 | 7799589,69 | 606304,32 | 7799663,64 | 963 | 1,33 | 1,63 |
| #51 | 607667,03 | 7799825,08 | 607710,99 | 7799868,21 | 881 | 0,43 | 0,52 |
| #52 | 607471,66 | 7798837,63 | 607511,48 | 7798893,71 | 924 | 1,11 | 1,36 |
| #53 | 606633,68 | 7798479,84 | 606676,36 | 7798533,48 | 913 | 0,70 | 0,86 |
| #54 | 607251,58 | 7798089,69 | 607295,68 | 7798135,59 | 890 | 0,54 | 0,66 |
| #55 | 604996,57 | 7797906,07 | 605039,84 | 7797950,69 | 885 | 0,75 | 0,92 |
| #56 | 603160,55 | 7798620,47 | 603203,25 | 7798670,60 | 899 | 0,39 | 0,48 |
| #57 | 604925,36 | 7798828,79 | 604975,21 | 7798860,56 | 842 | 0,64 | 0,78 |
| #58 | 602853,95 | 7799719,13 | 602903,71 | 7799753,00 | 847 | 1,11 | 1,36 |
| #59 | 602281,38 | 7798854,08 | 602327,67 | 7798891,46 | 861 | 0,74 | 0,91 |
| #60 | 602243,13 | 7797477,07 | 602289,45 | 7797521,33 | 888 | 0,79 | 0,97 |
| #61 | 603279,43 | 7796946,86 | 603321,27 | 7796998,11 | 901 | 0,75 | 0,93 |
| #62 | 604378,36 | 7797604,57 | 604427,27 | 7797640,47 | 861 | 0,84 | 1,03 |
| #63 | 604247,46 | 7798686,32 | 604292,95 | 7798723,43 | 859 | 0,85 | 1,04 |
| #65 | 604711,91 | 7796288,47 | 604756,21 | 7796337,98 | 898 | 0,33 | 0,41 |
| #66 | 605251,10 | 7797125,92 | 605291,08 | 7797187,41 | 926 | 0,80 | 0,99 |
| #67 | 606328,45 | 7797789,74 | 606371,89 | 7797837,75 | 889 | 0,60 | 0,73 |
| #68 | 607424,45 | 7796937,81 | 607473,49 | 7796969,30 | 853 | 1,38 | 1,69 |
| #69 | 607438,58 | 7795699,45 | 607485,43 | 7795742,50 | 871 | 0,77 | 0,94 |
| #71 | 606848,21 | 7795726,00 | 606892,16 | 7795778,78 | 896 | 1,25 | 1,53 |
| #70 | 603728,58 | 7796046,30 | 603770,08 | 7796104,39 | 930 | 1,20 | 1,47 |
| #72 | 602950,08 | 7795972,29 | 602990,11 | 7796034,48 | 944 | 1,32 | 1,62 |
| #73 | 602385,71 | 7795056,50 | 602428,25 | 7795118,69 | 929 | 1,04 | 1,28 |
| #74 | 603646,11 | 7794311,91 | 603688,24 | 7794372,35 | 923 | 0,76 | 0,93 |
| #75 | 604398,05 | 7795178,55 | 604443,87 | 7795226,65 | 888 | 0,53 | 0,65 |
| #76 | 605519,46 | 7795148,05 | 605562,28 | 7795205,41 | 916 | 0,35 | 0,43 |
| #77 | 607278,50 | 7794778,35 | 607324,40 | 7794832,91 | 912 | 1,37 | 1,68 |
| #78 | 607389,59 | 7795276,33 | 607434,56 | 7795322,21 | 882 | 0,49 | 0,60 |
| #79 | 606510,94 | 7796367,21 | 606559,03 | 7796404,79 | 862 | 0,28 | 0,34 |
| #81 | 605125,14 | 7794041,32 | 605171,63 | 7794092,75 | 891 | 1,42 | 1,74 |
| #82 | 604611,60 | 7794136,22 | 604653,13 | 7794188,75 | 904 | 1,04 | 1,28 |
| #85 | 604519,52 | 7793561,67 | 604562,00 | 7793619,81 | 921 | 0,04 | 0,05 |
| #84 | 604873,74 | 7793447,55 | 604909,73 | 7793517,62 | 954 | 1,29 | 1,58 |
| #86 | 604944,36 | 7793248,69 | 604986,71 | 7793311,46 | 928 | 0,89 | 1,09 |
| #87 | 605350,56 | 7793368,47 | 605391,07 | 7793430,02 | 921 | 1,56 | 1,91 |
| #88 | 606338,08 | 7793385,99 | 606386,05 | 7793431,35 | 878 | 0,71 | 0,87 |
| #89 | 606978,73 | 7793609,15 | 607024,00 | 7793659,64 | 897 | 0,22 | 0,27 |
| #90 | 607460,63 | 7794085,96 | 607499,59 | 7794154,25 | 953 | 0,48 | 0,58 |
| #91 | 607661,75 | 7793554,35 | 607700,89 | 7793618,93 | 937 | 0,55 | 0,68 |
| #93 | 607560,06 | 7793411,42 | 607597,81 | 7793484,00 | 963 | 0,13 | 0,15 |
| #95 | 607471,36 | 7793709,71 | 607509,33 | 7793774,22 | 946 | 1,13 | 1,38 |
| #94 | 607528,99 | 7792973,02 | 607569,50 | 7793037,61 | 942 | 0,45 | 0,55 |
| #96 | 606880,44 | 7792369,09 | 606923,58 | 7792432,83 | 933 | 0,92 | 1,12 |
| #97 | 606312,10 | 7792880,92 | 606357,29 | 7792929,66 | 895 | 0,41 | 0,50 |
| #98 | 605294,64 | 7792273,03 | 605339,31 | 7792323,11 | 898 | 0,39 | 0,47 |
| #99 | 604330,84 | 7792320,48 | 604374,86 | 7792377,53 | 920 | 0,50 | 0,62 |
| #100 | 603285,12 | 7792915,36 | 603328,56 | 7792968,59 | 906 | 0,39 | 0,47 |
| #101 | 603872,66 | 7792962,82 | 603916,52 | 7793020,79 | 917 | 0,62 | 0,76 |

| | | | | | | | |
|------|-----------|------------|-----------|------------|------|------|------|
| #102 | 602773,93 | 7791386,35 | 602817,14 | 7791439,18 | 913 | 0,91 | 1,11 |
| #103 | 602149,02 | 7790666,47 | 602193,34 | 7790731,76 | 943 | 1,34 | 1,64 |
| #104 | 603273,19 | 7790446,83 | 603311,75 | 7790518,08 | 964 | 0,36 | 0,45 |
| #105 | 605292,27 | 7790761,46 | 605330,02 | 7790834,85 | 965 | 0,57 | 0,70 |
| #108 | 605627,04 | 7788869,95 | 605662,72 | 7788956,82 | 1017 | 1,18 | 1,45 |
| #110 | 607343,98 | 7788097,82 | 607362,90 | 7788228,17 | 1135 | 1,17 | 1,44 |
| #111 | 607526,70 | 7788371,67 | 607547,38 | 7788499,81 | 1134 | 0,22 | 0,27 |
| #112 | 604296,18 | 7787270,02 | 604331,51 | 7787361,93 | 1030 | 0,55 | 0,68 |
| #113 | 603432,92 | 7787269,06 | 603469,70 | 7787357,06 | 1019 | 0,69 | 0,85 |
| #114 | 601783,14 | 7785531,48 | 601821,28 | 7785617,07 | 1012 | 0,91 | 1,12 |
| #115 | 600833,54 | 7786543,89 | 600870,98 | 7786622,66 | 989 | 0,84 | 1,03 |
| #116 | 601127,04 | 7786962,10 | 601166,07 | 7787030,56 | 963 | 0,75 | 0,91 |
| #117 | 601528,94 | 7787340,98 | 601564,68 | 7787426,08 | 1011 | 0,12 | 0,15 |
| #118 | 600698,76 | 7787301,65 | 600738,70 | 7787374,31 | 972 | 0,43 | 0,53 |
| #119 | 603377,28 | 7787894,92 | 603415,28 | 7787973,78 | 991 | 0,34 | 0,42 |
| #120 | 604073,64 | 7789025,81 | 604113,40 | 7789096,62 | 965 | 0,45 | 0,56 |
| #121 | 605140,24 | 7790136,07 | 605173,85 | 7790218,13 | 999 | 1,15 | 1,41 |
| #122 | 602944,21 | 7788373,55 | 602977,73 | 7788463,09 | 1024 | 0,49 | 0,61 |
| #124 | 601007,61 | 7788426,29 | 601046,17 | 7788502,02 | 977 | 0,65 | 0,80 |
| #125 | 599750,14 | 7788581,88 | 599787,96 | 7788652,88 | 975 | 0,80 | 0,98 |
| #126 | 601925,33 | 7789316,71 | 601955,32 | 7789411,17 | 1045 | 1,36 | 1,67 |
| #127 | 601302,49 | 7789921,55 | 601343,91 | 7789984,97 | 940 | 0,35 | 0,42 |
| #128 | 600247,50 | 7789429,57 | 600285,23 | 7789500,98 | 966 | 0,78 | 0,96 |
| #129 | 603760,99 | 7789970,14 | 603801,50 | 7790035,85 | 948 | 0,45 | 0,55 |
| #130 | 606311,23 | 7791358,38 | 606348,01 | 7791432,10 | 971 | 0,71 | 0,87 |
| #131 | 604932,90 | 7791240,10 | 604970,34 | 7791321,50 | 992 | 0,67 | 0,83 |
| #133 | 600341,93 | 7790308,73 | 600384,77 | 7790373,85 | 954 | 1,25 | 1,54 |
| #132 | 599714,59 | 7790938,31 | 599757,43 | 7791005,17 | 949 | 1,14 | 1,40 |
| #134 | 599520,78 | 7790277,70 | 599560,56 | 7790345,09 | 962 | 0,57 | 0,70 |
| #135 | 598886,26 | 7789354,01 | 598924,38 | 7789425,76 | 974 | 0,44 | 0,54 |
| #136 | 599024,76 | 7790474,21 | 599062,41 | 7790546,83 | 972 | 0,74 | 0,91 |
| #137 | 599011,71 | 7790917,16 | 599049,13 | 7790997,65 | 1003 | 0,95 | 1,16 |
| #139 | 603577,97 | 7789103,12 | 603616,57 | 7789176,69 | 969 | 0,41 | 0,50 |

A 2. Parâmetros de 96 pontos de controle utilizados na imagem “B”.

| ID do CGP | X (entrada) | Y (entrada) | X (referência) | Y (referência) | Z (referência) | RMS | Contribuição |
|-----------|-------------|-------------|----------------|----------------|----------------|------|--------------|
| #1 | 609596,71 | 7811570,81 | 609652,67 | 7811568,31 | 780 | 1,03 | 1,27 |
| #2 | 609636,95 | 7811055,42 | 609693,13 | 7811057,46 | 787 | 0,51 | 0,63 |
| #3 | 609324,01 | 7810820,40 | 609378,98 | 7810823,67 | 786 | 0,53 | 0,66 |
| #4 | 608660,45 | 7811031,15 | 608704,08 | 7811072,57 | 905 | 1,33 | 1,64 |
| #5 | 607520,46 | 7810838,92 | 607572,98 | 7810839,02 | 782 | 1,21 | 1,49 |
| #8 | 610248,77 | 7810559,83 | 610305,35 | 7810564,76 | 793 | 0,86 | 1,06 |
| #9 | 611572,05 | 7810420,61 | 611625,13 | 7810426,08 | 803 | 1,01 | 1,24 |
| #10 | 611596,32 | 7810653,71 | 611651,42 | 7810658,59 | 788 | 0,99 | 1,22 |
| #11 | 612438,06 | 7810275,63 | 612491,75 | 7810279,15 | 790 | 0,61 | 0,75 |
| #12 | 612264,98 | 7809546,30 | 612321,11 | 7809539,35 | 766 | 0,79 | 0,97 |
| #13 | 611603,72 | 7809107,22 | 611656,06 | 7809108,36 | 786 | 1,32 | 1,63 |

| | | | | | | | |
|-----|-----------|------------|-----------|------------|------|------|------|
| #14 | 610992,66 | 7809649,47 | 611044,12 | 7809662,56 | 821 | 0,57 | 0,70 |
| #16 | 608639,72 | 7810377,70 | 608689,64 | 7810408,03 | 862 | 1,02 | 1,26 |
| #17 | 608030,71 | 7810468,99 | 608082,85 | 7810479,69 | 807 | 0,83 | 1,02 |
| #18 | 607416,24 | 7809623,59 | 607473,48 | 7809624,41 | 781 | 0,71 | 0,88 |
| #19 | 607976,21 | 7808633,77 | 608029,75 | 7808643,34 | 811 | 0,48 | 0,59 |
| #21 | 609410,18 | 7808108,55 | 609470,17 | 7808102,02 | 757 | 0,79 | 0,97 |
| #20 | 611721,57 | 7807793,14 | 611778,25 | 7807784,45 | 757 | 0,91 | 1,12 |
| #22 | 613169,33 | 7806950,65 | 613225,89 | 7806955,46 | 795 | 0,87 | 1,07 |
| #23 | 614150,13 | 7807032,90 | 614198,19 | 7807053,93 | 851 | 0,76 | 0,93 |
| #24 | 613505,01 | 7806489,96 | 613556,86 | 7806506,43 | 827 | 0,73 | 0,90 |
| #25 | 613659,74 | 7806074,88 | 613715,65 | 7806084,72 | 808 | 1,29 | 1,59 |
| #27 | 612842,18 | 7805520,58 | 612894,39 | 7805527,42 | 801 | 0,80 | 0,98 |
| #29 | 611348,94 | 7807131,67 | 611404,48 | 7807135,90 | 789 | 0,61 | 0,75 |
| #28 | 609418,36 | 7809050,00 | 609476,87 | 7809051,65 | 781 | 1,05 | 1,30 |
| #30 | 610718,81 | 7808397,39 | 610778,10 | 7808388,15 | 752 | 0,40 | 0,49 |
| #32 | 608839,32 | 7806160,25 | 608896,38 | 7806164,62 | 793 | 0,50 | 0,62 |
| #33 | 608152,64 | 7807288,36 | 608209,16 | 7807284,37 | 768 | 0,77 | 0,95 |
| #34 | 607459,84 | 7805933,41 | 607515,76 | 7805935,20 | 789 | 0,68 | 0,83 |
| #35 | 607331,77 | 7807564,93 | 607386,87 | 7807567,40 | 789 | 0,42 | 0,52 |
| #36 | 607683,28 | 7805100,95 | 607739,51 | 7805109,82 | 803 | 0,45 | 0,55 |
| #37 | 609768,50 | 7803796,41 | 609821,26 | 7803813,76 | 832 | 0,71 | 0,87 |
| #38 | 610773,31 | 7805243,32 | 610826,05 | 7805255,72 | 808 | 1,16 | 1,42 |
| #39 | 608992,59 | 7804410,19 | 609047,43 | 7804418,49 | 800 | 0,40 | 0,49 |
| #40 | 607334,49 | 7804045,06 | 607391,00 | 7804058,64 | 817 | 1,09 | 1,34 |
| #41 | 611648,68 | 7804219,45 | 611701,95 | 7804223,10 | 797 | 1,01 | 1,25 |
| #42 | 613440,98 | 7803056,60 | 613492,42 | 7803069,83 | 815 | 1,03 | 1,26 |
| #43 | 613986,64 | 7804290,97 | 614041,99 | 7804298,37 | 801 | 0,89 | 1,09 |
| #45 | 613636,49 | 7801848,79 | 613691,42 | 7801860,38 | 819 | 1,19 | 1,46 |
| #47 | 611080,54 | 7802442,14 | 611133,31 | 7802457,37 | 828 | 0,87 | 1,07 |
| #46 | 608728,96 | 7801656,69 | 608780,90 | 7801675,29 | 833 | 0,41 | 0,51 |
| #48 | 607601,53 | 7799945,46 | 607648,26 | 7799978,65 | 869 | 0,88 | 1,08 |
| #49 | 607399,89 | 7798683,15 | 607444,62 | 7798733,10 | 918 | 0,44 | 0,54 |
| #50 | 609049,13 | 7799219,27 | 609095,38 | 7799251,22 | 868 | 0,96 | 1,18 |
| #51 | 609572,31 | 7800526,54 | 609625,87 | 7800545,23 | 823 | 1,14 | 1,41 |
| #52 | 612066,95 | 7799424,32 | 612112,32 | 7799460,02 | 883 | 0,15 | 0,19 |
| #53 | 611640,93 | 7801448,70 | 611694,73 | 7801457,22 | 802 | 0,41 | 0,51 |
| #54 | 614105,93 | 7800214,76 | 614154,89 | 7800232,82 | 840 | 0,97 | 1,19 |
| #55 | 611042,15 | 7800317,55 | 611094,65 | 7800333,86 | 826 | 0,19 | 0,24 |
| #56 | 611136,27 | 7798928,86 | 611183,32 | 7798963,04 | 873 | 0,51 | 0,63 |
| #58 | 614264,72 | 7798541,99 | 614317,81 | 7798557,83 | 830 | 0,68 | 0,84 |
| #59 | 612382,91 | 7798394,17 | 612431,44 | 7798423,78 | 861 | 0,53 | 0,65 |
| #60 | 609256,20 | 7797912,60 | 609304,18 | 7797943,30 | 867 | 0,55 | 0,67 |
| #61 | 607422,32 | 7796944,28 | 607473,49 | 7796968,92 | 853 | 1,38 | 1,70 |
| #62 | 608695,53 | 7796098,94 | 608742,75 | 7796133,75 | 879 | 0,73 | 0,90 |
| #63 | 607752,03 | 7795042,26 | 607799,83 | 7795084,62 | 887 | 1,10 | 1,36 |
| #64 | 607619,22 | 7793803,70 | 607662,18 | 7793858,67 | 925 | 0,94 | 1,16 |
| #65 | 608992,90 | 7793582,55 | 609026,30 | 7793664,31 | 1010 | 0,51 | 0,62 |
| #66 | 608156,22 | 7793492,48 | 608202,99 | 7793537,49 | 901 | 0,24 | 0,30 |
| #67 | 608624,50 | 7794377,08 | 608671,10 | 7794418,55 | 896 | 0,39 | 0,48 |

| | | | | | | | |
|------|-----------|------------|-----------|------------|------|------|------|
| #68 | 610305,94 | 7794623,64 | 610350,73 | 7794672,19 | 915 | 0,35 | 0,43 |
| #69 | 610524,20 | 7793047,29 | 610561,58 | 7793118,36 | 983 | 0,18 | 0,23 |
| #71 | 614215,05 | 7793118,31 | 614233,78 | 7793238,99 | 1128 | 0,49 | 0,60 |
| #74 | 614094,95 | 7794747,20 | 614121,39 | 7794835,62 | 1038 | 0,74 | 0,91 |
| #75 | 614058,00 | 7795405,46 | 614092,52 | 7795471,28 | 965 | 1,02 | 1,25 |
| #76 | 614066,66 | 7795647,39 | 614106,95 | 7795703,79 | 933 | 1,20 | 1,47 |
| #77 | 613510,61 | 7795657,79 | 613545,01 | 7795730,60 | 983 | 0,91 | 1,12 |
| #78 | 613197,65 | 7796101,24 | 613242,91 | 7796141,49 | 897 | 0,49 | 0,60 |
| #79 | 614282,61 | 7796970,26 | 614332,24 | 7796991,10 | 842 | 0,82 | 1,01 |
| #80 | 612876,60 | 7793131,59 | 612904,71 | 7793225,07 | 1054 | 0,80 | 0,98 |
| #82 | 611501,77 | 7793754,04 | 611540,59 | 7793812,79 | 942 | 1,10 | 1,36 |
| #83 | 611125,87 | 7791440,33 | 611149,82 | 7791554,21 | 1112 | 0,68 | 0,83 |
| #84 | 609602,07 | 7792005,63 | 609635,67 | 7792091,91 | 1021 | 0,82 | 1,00 |
| #86 | 608468,96 | 7790639,01 | 608503,03 | 7790733,98 | 1050 | 1,05 | 1,29 |
| #87 | 608543,66 | 7792943,93 | 608586,55 | 7793004,94 | 947 | 0,66 | 0,81 |
| #88 | 607919,48 | 7792733,17 | 607960,17 | 7792800,27 | 965 | 0,46 | 0,57 |
| #89 | 609850,94 | 7792783,99 | 609894,99 | 7792833,78 | 923 | 0,59 | 0,73 |
| #91 | 607407,31 | 7790545,34 | 607451,84 | 7790609,22 | 958 | 1,17 | 1,45 |
| #92 | 608085,77 | 7788389,26 | 608111,74 | 7788499,11 | 1098 | 0,88 | 1,08 |
| #93 | 607525,68 | 7788377,14 | 607547,74 | 7788499,11 | 1134 | 0,77 | 0,95 |
| #94 | 609046,02 | 7797074,19 | 609094,87 | 7797098,84 | 844 | 1,19 | 1,47 |
| #96 | 613217,86 | 7796623,81 | 613270,23 | 7796649,81 | 852 | 1,07 | 1,32 |
| #97 | 610576,17 | 7796821,86 | 610627,57 | 7796847,78 | 848 | 0,52 | 0,64 |
| #99 | 610220,03 | 7796051,01 | 610266,69 | 7796088,90 | 888 | 0,38 | 0,46 |
| #98 | 611330,82 | 7797552,38 | 611382,84 | 7797571,59 | 838 | 0,82 | 1,01 |
| #100 | 612597,12 | 7796299,63 | 612644,88 | 7796325,53 | 857 | 0,95 | 1,17 |
| #101 | 610133,47 | 7802020,81 | 610182,14 | 7802049,06 | 864 | 0,72 | 0,89 |
| #104 | 609154,61 | 7795296,90 | 609200,55 | 7795339,30 | 903 | 0,85 | 1,04 |
| #106 | 614086,35 | 7806902,96 | 614133,24 | 7806931,75 | 865 | 0,40 | 0,49 |
| #90 | 613582,41 | 7807510,65 | 613639,35 | 7807513,79 | 792 | 0,78 | 0,96 |
| #95 | 613495,41 | 7807064,07 | 613542,94 | 7807092,08 | 868 | 0,79 | 0,97 |
| #102 | 612542,16 | 7805983,28 | 612596,93 | 7805988,31 | 798 | 0,22 | 0,27 |
| #103 | 613862,74 | 7804892,36 | 613917,23 | 7804895,88 | 796 | 0,20 | 0,25 |
| #108 | 614164,97 | 7806176,70 | 614224,49 | 7806163,59 | 750 | 0,47 | 0,57 |
| #110 | 612115,71 | 7805421,43 | 612167,48 | 7805433,59 | 820 | 0,52 | 0,64 |
| #112 | 613989,04 | 7805795,84 | 614046,63 | 7805785,70 | 765 | 1,21 | 1,49 |

A 3. Parâmetros de 78 pontos de controle utilizados no agrupamento de imagens “CDE”.

| ID do GCP | X (entrada) | Y (entrada) | X (referência) | Y (referência) | Z (referência) | RMS | Contribuição |
|-----------|-------------|-------------|----------------|----------------|----------------|------|--------------|
| #5 | 614811,30 | 7807729,15 | 614829,06 | 7807750,27 | 696 | 0,14 | 0,17 |
| #6 | 618630,84 | 7807051,11 | 618659,27 | 7807077,93 | 749 | 1,00 | 1,25 |
| #7 | 618060,32 | 7807077,45 | 618085,73 | 7807101,85 | 752 | 1,11 | 1,37 |
| #10 | 615036,58 | 7806594,70 | 615057,33 | 7806616,70 | 712 | 0,54 | 0,67 |
| #12 | 615223,83 | 7807168,87 | 615248,69 | 7807193,37 | 748 | 1,02 | 1,27 |
| #13 | 615907,72 | 7808377,20 | 615928,31 | 7808401,81 | 723 | 0,64 | 0,79 |
| #15 | 618434,81 | 7806231,91 | 618455,44 | 7806256,87 | 712 | 0,87 | 1,07 |
| #18 | 618209,94 | 7803996,26 | 618234,44 | 7804025,09 | 741 | 0,74 | 0,92 |

| | | | | | | | |
|-----|-----------|------------|-----------|------------|-----|------|------|
| #19 | 618360,22 | 7803812,28 | 618386,28 | 7803843,10 | 776 | 0,89 | 1,11 |
| #21 | 617370,27 | 7803796,23 | 617402,47 | 7803825,94 | 800 | 1,24 | 1,53 |
| #22 | 617825,94 | 7803867,37 | 617855,89 | 7803897,70 | 785 | 0,47 | 0,59 |
| #23 | 617153,13 | 7803601,02 | 617193,43 | 7803642,39 | 868 | 1,01 | 1,25 |
| #24 | 617676,18 | 7803480,15 | 617711,85 | 7803514,19 | 832 | 1,00 | 1,24 |
| #25 | 617516,81 | 7804446,58 | 617543,36 | 7804476,34 | 777 | 0,87 | 1,08 |
| #26 | 617134,95 | 7804167,40 | 617168,02 | 7804200,36 | 804 | 0,63 | 0,78 |
| #27 | 617047,23 | 7804027,28 | 617080,29 | 7804063,24 | 832 | 0,69 | 0,86 |
| #28 | 616926,36 | 7804433,21 | 616960,02 | 7804469,37 | 828 | 0,44 | 0,55 |
| #29 | 616828,49 | 7804833,79 | 616858,92 | 7804865,04 | 795 | 0,19 | 0,24 |
| #30 | 617196,45 | 7804814,00 | 617221,47 | 7804841,80 | 749 | 0,43 | 0,53 |
| #31 | 615351,85 | 7804595,26 | 615373,86 | 7804620,43 | 738 | 0,50 | 0,62 |
| #33 | 616849,89 | 7805363,26 | 616876,93 | 7805393,18 | 769 | 0,49 | 0,60 |
| #34 | 615872,77 | 7805325,29 | 615903,74 | 7805356,57 | 794 | 0,43 | 0,53 |
| #35 | 615820,35 | 7805585,75 | 615849,12 | 7805615,71 | 779 | 0,24 | 0,30 |
| #36 | 613198,12 | 7804192,01 | 613223,53 | 7804221,27 | 779 | 0,78 | 0,97 |
| #39 | 615187,12 | 7805318,88 | 615210,82 | 7805347,35 | 749 | 0,84 | 1,04 |
| #42 | 614338,89 | 7803531,03 | 614363,64 | 7803559,84 | 753 | 1,09 | 1,35 |
| #43 | 616363,17 | 7803452,95 | 616398,53 | 7803487,39 | 820 | 0,91 | 1,13 |
| #44 | 616761,61 | 7803347,59 | 616800,64 | 7803388,54 | 865 | 0,91 | 1,13 |
| #46 | 616221,98 | 7803887,76 | 616246,89 | 7803914,86 | 761 | 0,68 | 0,84 |
| #47 | 613191,70 | 7803708,59 | 613221,48 | 7803739,93 | 788 | 0,88 | 1,09 |
| #48 | 613470,34 | 7802894,07 | 613504,56 | 7802927,95 | 826 | 0,51 | 0,64 |
| #50 | 614007,30 | 7802764,64 | 614034,50 | 7802791,32 | 775 | 0,61 | 0,76 |
| #49 | 617699,68 | 7804189,39 | 617723,37 | 7804215,02 | 735 | 0,12 | 0,15 |
| #51 | 614026,02 | 7803174,31 | 614054,69 | 7803203,78 | 781 | 0,43 | 0,53 |
| #53 | 615373,76 | 7802245,87 | 615407,48 | 7802276,91 | 824 | 0,99 | 1,23 |
| #54 | 615147,53 | 7802906,37 | 615179,77 | 7802937,78 | 800 | 0,73 | 0,90 |
| #55 | 613316,85 | 7801822,29 | 613347,76 | 7801852,54 | 806 | 0,26 | 0,32 |
| #57 | 613945,80 | 7801511,56 | 613979,13 | 7801545,65 | 843 | 0,86 | 1,07 |
| #56 | 613115,22 | 7801033,97 | 613152,14 | 7801070,57 | 851 | 0,66 | 0,81 |
| #58 | 614121,75 | 7800199,66 | 614154,57 | 7800233,23 | 840 | 1,03 | 1,27 |
| #61 | 615838,37 | 7800294,27 | 615874,80 | 7800328,45 | 840 | 0,19 | 0,23 |
| #60 | 615143,08 | 7799585,46 | 615179,26 | 7799615,83 | 834 | 1,25 | 1,55 |
| #63 | 615923,59 | 7798738,54 | 615957,09 | 7798767,10 | 807 | 0,87 | 1,08 |
| #62 | 616435,80 | 7799545,80 | 616470,99 | 7799580,12 | 826 | 0,50 | 0,62 |
| #64 | 615292,36 | 7800129,70 | 615325,72 | 7800163,36 | 833 | 0,73 | 0,90 |
| #65 | 613167,12 | 7799531,39 | 613204,06 | 7799567,76 | 867 | 0,53 | 0,65 |
| #66 | 613627,90 | 7798015,63 | 613662,76 | 7798044,11 | 821 | 1,45 | 1,79 |
| #67 | 614897,99 | 7798707,98 | 614932,28 | 7798740,41 | 826 | 0,19 | 0,24 |
| #68 | 613791,88 | 7798999,49 | 613825,72 | 7799030,44 | 833 | 0,87 | 1,08 |
| #69 | 613111,28 | 7797362,66 | 613147,66 | 7797396,24 | 838 | 0,47 | 0,58 |
| #70 | 614315,55 | 7796764,93 | 614355,19 | 7796801,08 | 864 | 0,15 | 0,18 |
| #71 | 615086,07 | 7797474,91 | 615122,12 | 7797506,75 | 843 | 0,94 | 1,17 |
| #72 | 615562,13 | 7798039,14 | 615597,24 | 7798072,33 | 832 | 0,45 | 0,56 |
| #73 | 615856,59 | 7798104,37 | 615889,61 | 7798137,44 | 820 | 0,96 | 1,19 |
| #76 | 615320,58 | 7798215,10 | 615354,43 | 7798245,91 | 807 | 0,40 | 0,49 |
| #77 | 615507,87 | 7798828,69 | 615539,65 | 7798860,40 | 809 | 0,70 | 0,87 |
| #78 | 616865,14 | 7797235,55 | 616917,19 | 7797278,67 | 945 | 1,35 | 1,67 |

| | | | | | | | |
|------|-----------|------------|-----------|------------|------|------|------|
| #79 | 617421,52 | 7797130,54 | 617474,67 | 7797180,99 | 977 | 0,79 | 0,98 |
| #80 | 617026,57 | 7796794,36 | 617081,28 | 7796844,73 | 990 | 0,52 | 0,64 |
| #86 | 615840,92 | 7797201,85 | 615880,59 | 7797237,39 | 856 | 0,18 | 0,22 |
| #87 | 613471,96 | 7796127,48 | 613516,58 | 7796167,10 | 902 | 0,57 | 0,71 |
| #89 | 617004,42 | 7795742,11 | 617063,70 | 7795794,22 | 1049 | 1,37 | 1,69 |
| #94 | 614040,41 | 7795422,87 | 614091,82 | 7795471,53 | 965 | 1,10 | 1,37 |
| #96 | 614264,03 | 7795305,92 | 614314,59 | 7795351,88 | 951 | 0,62 | 0,76 |
| #98 | 614776,08 | 7795695,49 | 614834,08 | 7795748,25 | 1015 | 1,04 | 1,29 |
| #100 | 614256,92 | 7796002,87 | 614296,31 | 7796037,58 | 854 | 0,31 | 0,38 |
| #101 | 613846,02 | 7795974,43 | 613888,24 | 7796013,84 | 888 | 0,36 | 0,44 |
| #106 | 613254,23 | 7793665,07 | 613310,02 | 7793716,95 | 1027 | 1,35 | 1,67 |
| #110 | 613166,49 | 7794518,91 | 613215,03 | 7794566,23 | 956 | 0,66 | 0,82 |
| #112 | 613153,78 | 7795227,15 | 613202,21 | 7795272,31 | 942 | 0,30 | 0,37 |
| #113 | 613195,74 | 7795725,60 | 613239,50 | 7795769,24 | 908 | 1,09 | 1,35 |
| #114 | 613232,61 | 7796615,04 | 613272,70 | 7796649,51 | 852 | 1,23 | 1,53 |
| #115 | 613170,31 | 7799253,48 | 613206,28 | 7799289,72 | 868 | 1,00 | 1,24 |
| #120 | 613968,83 | 7807923,47 | 613987,49 | 7807949,06 | 721 | 0,78 | 0,97 |
| #104 | 613525,98 | 7793431,42 | 613590,35 | 7793486,56 | 1064 | 0,98 | 1,21 |
| #92 | 613052,45 | 7805384,90 | 613081,50 | 7805419,07 | 799 | 1,04 | 1,29 |
| #93 | 613006,12 | 7806813,22 | 613032,76 | 7806839,19 | 770 | 1,36 | 1,69 |
| #95 | 613895,93 | 7804697,12 | 613927,08 | 7804727,85 | 803 | 0,71 | 0,87 |

APÊNDICE B

Exemplos dos arquivos e informações utilizadas no programa 6S para atenuação atmosférica de imagens.

B1. Exemplo de um arquivo infiles.txt, com os nomes dos arquivos de entrada no programa 6S. Informações entre parênteses são consideradas comentários pelo programa.

```
a4_atm.txt           (arquivo texto de entrada com as condições atmosféricas)
a4_atm.res           (condições atmosféricas do arquivo texto de saída)
a_corrgeo_b4.raw     (arquivo da imagem de entrada)
a_corrgeoatm_b4.raw  (arquivo da imagem de saída corrigida)
```

B2. Exemplo de um arquivo (*.txt) com os parâmetros de condições atmosféricas de entrada no programa 6S. As informações entre parênteses são comentários.

```
0

21.8 56.1 19.6 34.42 10 10 (1 Conds. Geoms. defs. usuário - Sat. QB2: ângs. zên./az.
sol.; zên./az. vis.; mês; dia; Fonte: metadados)

1 (2 modelo atmosférico tropical)

0 (3 Sem efeito de aerossóis devido à correl. com Umid.Rel.med. < 60%; Fonte: Pinto,
2001)

-1 (4 Valor padrão ao desprezar o efeito de aerossóis)

-.877 (5 superfície do pixel alvo acima do nível do mar; Fonte: metadados)

-1000 (6 sensor a bordo do satélite - aprox. 450 Km)

0

.7591

.8634 (7 Largura da banda def. usuário, limites inf. e sup. aprox. IV Prox.; Fonte:
Liedtke, 2002)

-1 (8 Valor padrão para valores de reflectância entre 0 e 255)

50412780 (9 Número de pixels da imagem A = número de bytes; Fonte: propriedades do
arquivo)
```

B3.Exemplo de um arquivo (*.res), sua estrutura geral impressa em todas as saídas do programa 6S. Tela de apresentação, seguida por nomes dos arquivos utilizados como entrada bem como os respectivos nomes de saída, parâmetros de saída calculados, mensagem de advertência (quando for o caso).

6s - Second Simulation of Satellite Signal in the Solar Spectrum.

Adapted by Mauro A. Homem Antunes for atmospheric corrections of
remotely sensed images in raw format (.RAW) of 8 bits.

April 4, 2001.

Please refer to the following paper and acknowledge the authors of
the model:

Vermote, E.F., Tanre, D., Deuze, J.L., Herman, M., and Morcrette,
J.J., (1997), Second simulation of the satellite signal in
the solar spectrum, 6S: An overview., IEEE Trans. Geosc.
and Remote Sens. 35(3):675-686.

The code is provided as is and is not to be sold. See notes on

http://loasys.univ-lille1.fr/informatique/sixs_gb.html

and on <http://www.ltid.inpe.br/dsr/mauro/6s/index.html>

| | |
|---|---------|
| a4_atm.txt | = File |
| with the atmospheric and sensor conditions | |
| a4_atm.res | = |
| Output file showing the atmospheric and sensor conditions | |
| a_corrgeo_b4.raw | = Image |
| input file | |
| a_corrgeoatm_b4.raw | = Image |
| output file | |

```

***** 6s version 4.1 *****
*
*
*          geometrical conditions identity
*          -----
*          user defined conditions
*
*
* month: 10 day : 10
*
* solar zenith angle:  21.80 deg  solar azimuthal angle:    56.10 deg
* view zenith angle:   19.60 deg  view azimuthal angle:    34.42 deg
* scattering angle:    172.08 deg  azimuthal angle difference: 21.68 deg
*
*
*          atmospheric model description
*          -----
*
*          atmospheric model identity :
*
*          tropical          (uh2o=4.12g/cm2,uo3=.247cm-atm)
*
*          aerossols type identity :
*
*          no aerossols computed
*
*
*          spectral condition
*          -----
*
*          constant
*
*          value of filter function :
*
*          wl inf= 0.759 mic  wl sup= 0.863 mic
*
*
*          target type
*          -----
*
*          homogeneous ground
*
*          constant reflectance over the spectra  0.000
*
*
*          target elevation description
*          -----
*
*          ground pressure [mb] 916.75

```

```

*           ground altitude [km] 0.877           *
*
*           gaseous content at target level:      *
*
*           uh2o= 2.708 g/cm2           uo3= 0.245 cm-atm      *
*
*
*           atmospheric correction activated      *
*
*           -----

```

ATTENTION !!!!

The program has caculated $\text{ainr}(1,1)/\text{tgasm} > \text{rapp}/\text{tgasm}$ 276 times, meaning that the atmospheric intrinsic reflectance was greater than the apparent reflectance.

In such case CHOOSE OTHER ATMOSPHERIC AND AEROSSOL CONDITIONS.

If left unchanged this would lead to Negative reflectance values, which would appear as bright pixels in the image (DNs close to 255).

In this run the values of $\text{ainr}(1,1)/\text{tgasm}$ were decreased to avoid these bright pixels, but it is advisable to change the input values to more suitable atmospheric conditions.

APÊNDICE C

Matrizes de erro referentes aos processos de Classificação Tradicional e Classificação Contextual das imagens *QuickBird*.

C 1. Matriz de erros obtida pela comparação das categorias da imagem classificada com as categorias da imagem de referência. Foi empregado o processo de CMV com probabilidades uniformes *a priori* para as classes, através do método Classificação Tradicional.

| Imagem Classificada | Imagem de Referência | | | | | | | | | | Total | Erro de Comissão |
|---------------------|----------------------|-------|--------|--------|--------|--------|--------|--------|-------|--------|---------|------------------|
| | FN | FP | CE | CC | CP | SE | AI | RH | NU | SO | | |
| FN | 133913 | 402 | 17923 | 0 | 0 | 0 | 225 | 0 | 0 | 0 | 152463 | 0,1217 |
| FP | 28004 | 16600 | 7319 | 0 | 0 | 0 | 8 | 0 | 0 | 0 | 51931 | 0,6803 |
| CE | 941 | 7 | 101754 | 4 | 85 | 27 | 1748 | 0 | 0 | 0 | 104566 | 0,0269 |
| CC | 0 | 0 | 1472 | 142490 | 0 | 0 | 514 | 0 | 0 | 0 | 144476 | 0,0137 |
| CP | 0 | 0 | 0 | 0 | 29420 | 0 | 78 | 0 | 0 | 0 | 29498 | 0,0026 |
| SE | 0 | 0 | 0 | 0 | 0 | 52538 | 68295 | 0 | 0 | 0 | 120833 | 0,5652 |
| AI | 0 | 0 | 0 | 0 | 0 | 187 | 267521 | 0 | 0 | 0 | 267708 | 0,0007 |
| RH | 0 | 0 | 0 | 0 | 0 | 0 | 403 | 88416 | 0 | 747 | 89566 | 0,0128 |
| NU | 0 | 0 | 0 | 0 | 0 | 0 | 1117 | 0 | 65712 | 0 | 66829 | 0,0167 |
| SO | 0 | 0 | 28 | 0 | 0 | 6026 | 6472 | 4700 | 0 | 113985 | 131211 | 0,1313 |
| Total | 162858 | 17009 | 128496 | 142494 | 29505 | 58778 | 346381 | 93116 | 65712 | 114732 | 1159081 | - |
| Erro de Omissão | 0,1777 | 0,024 | 0,2081 | 0 | 0,0029 | 0,1062 | 0,2277 | 0,0505 | 0 | 0,0065 | - | 0,1266 |

Legenda: FN – Floresta Nativa; FP – Floresta Plantada; CE - Cerrado; CC – Campo Cerrado; CP – Campo plantado; SE – Solo Exposto, AI – Área impermeável; RH – Recursos Hídricos; NU – Nuvens; SO – Sombra.

C 2. Matriz de erros obtida pela avaliação do método de Classificação Contextual utilizando imagens com valores fundamentados em probabilidade como probabilidades iniciais para as classes informacionais de vegetação no processo de CMV.


| Imagem classificada | Imagem de referência | | | | | | | | | | Total | Erro de Comissão |
|---------------------|----------------------|---------|--------|--------|--------|--------|---------|--------|-------|--------|---------|------------------|
| | FN | FP | CE | CC | CP | SE | AI | RH | NU | SO | | |
| FN | 144424 | 2688 | 10524 | 0 | 0 | 0 | 6 | 0 | 0 | 0 | 157642 | 0,0838 |
| FP | 10973 | 13899 | 2249 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 27121 | 0,4875 |
| CE | 7461 | 4221 | 14655 | 5 | 53 | 0 | 58 | 0 | 0 | 0 | 122654 | 0,0652 |
| CC | 0 | 0 | 1068 | 142489 | 0 | 0 | 6 | 0 | 0 | 0 | 143563 | 0,0075 |
| CP | 0 | 0 | 0 | 0 | 29452 | 0 | 0 | 0 | 0 | 0 | 29452 | 0 |
| SE | 0 | 0 | 0 | 0 | 0 | 28664 | 155 | 0 | 0 | 0 | 28819 | 0,0054 |
| AI | 0 | 0 | 0 | 0 | 0 | 24764 | 339852 | 0 | 0 | 0 | 364616 | 0,0679 |
| RH | 0 | 0 | 0 | 0 | 0 | 0 | 252 | 87651 | 0 | 143 | 88046 | 0,0045 |
| NU | 0 | 0 | 0 | 0 | 0 | 0 | 293 | 0 | 65712 | 0 | 66005 | 0,0044 |
| SO | 0 | 0 | 0 | 0 | 0 | 5350 | 5759 | 5465 | 0 | 114589 | 131163 | 0,1264 |
| Total | 162858 | 170091 | 28496 | 142494 | 29505 | 58778 | 346381 | 93116 | 65712 | 114732 | 1159081 | - |
| Erro de Omissão | 0,1132 | 0,18280 | 0,1077 | 0 | 0,0018 | 0,5123 | 0,01880 | 0,0587 | 0 | 0,0012 | - | 0,067 |

Legenda: FN – Floresta Nativa; FP – Floresta Plantada; CE - Cerrado; CC – Campo Cerrado; CP – Campo plantado; SE – Solo Exposto, AI – Área impermeável; RH – Recursos Hídricos; NU – Nuvens; SO – Sombra.


APÊNDICE D

Carta-imagem do método de Classificação Contextual, obtidas por operações com filtro da moda e diferentes dimensões de janelas móveis.

D 1. Carta-imagem obtida pelo método de Classificação Contextual, submetida a operação de filtragem com janela-móvel de dimensões 3x3 pixels.



D 2. Carta-imagem obtida pelo método de Classificação Contextual, submetida a operação de filtragem com janela-móvel de dimensões 5x5 pixels.



D 3. Carta-imagem obtida pelo método de Classificação Contextual, submetida a operação de filtragem com janela-móvel de dimensões 7x7 pixels.

