



**UNIVERSIDADE ESTADUAL PAULISTA**

**CAMPUS DE PRESIDENTE PRUDENTE**

**FACULDADE DE CIÊNCIAS E TECNOLOGIA**

*Programa de Pós-Graduação em Ciências Cartográficas*

---

FERNANDA DE ALMEIDA PRADO

**SISTEMA HIERÁRQUICO DE CLASSIFICAÇÃO  
PARA MAPEAMENTO DA COBERTURA DA TERRA  
NAS ESCALAS REGIONAL E URBANA**



DISSERTAÇÃO DE MESTRADO

Presidente Prudente  
2009

# **Livros Grátis**

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

Milhares de livros grátis para download.

FERNANDA DE ALMEIDA PRADO

**SISTEMA HIERÁRQUICO DE CLASSIFICAÇÃO  
PARA MAPEAMENTO DA COBERTURA DA TERRA  
NAS ESCALAS REGIONAL E URBANA**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Cartográficas da Universidade Estadual Paulista, campus de Presidente Prudente, como parte dos requisitos para obtenção do título de Mestre em Ciências Cartográficas.

Orientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Maria de Lourdes Bueno Trindade Galo

Presidente Prudente  
2009

P917s Prado, Fernanda de Almeida.  
Sistema hierárquico de classificação para mapeamento da  
cobertura da terra nas escalas regional e urbana / Fernanda de  
Almeida Prado. - Presidente Prudente : [s.n], 2009  
xiv, 168 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista,  
Faculdade de Ciências e Tecnologia

Orientadora: Maria de Lourdes Bueno Trindade Galo

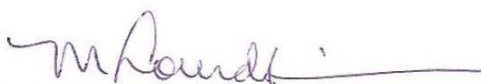
Banca: Eivaldo Antonio da Silva, Edson Eyji Sano

Inclui bibliografia

1. Cartografia. 2. Sensoriamento remoto. 3. Sistema  
hierárquico de classificação. 4. Cobertura da Terra. I. Autor. II.  
Título. III. Presidente Prudente - Faculdade de Ciências e  
Tecnologia.

CDD(18.ed.) 621.71

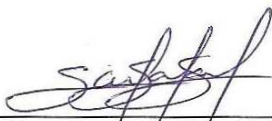
**BANCA EXAMINADORA**



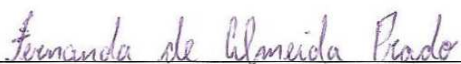
PROF. DR. MARIA DE LOURDES BUENO TRINDADE GALO  
(ORIENTADORA)



PROF. DR. ERIVALDO ANTONIO DA SILVA  
(FCT/UNESP)



PROF. DR. EDSON EYJI SANO  
(CPAC-EMBRAPA)



FERNANDA DE ALMEIDA PRADO

PRESIDENTE PRUDENTE (SP), 16 DE FEVEREIRO DE 2009

RESULTADO: APROVADA



*Dedico:*

*à minha família,  
pela educação, apoio e auxílio nos momentos de dificuldade;*

*aos amigos e à todos aqueles que fazem parte  
e que são importantes na minha vida.*

## AGRADECIMENTOS

À Deus, pela vida, saúde, inteligência, graças concedidas e por me permitir alcançar mais este objetivo.

À Prof<sup>a</sup>. Dr<sup>a</sup>. Maria de Lourdes Bueno Trindade Galo, pela orientação, exemplo profissional, paciência e incentivo.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pela concessão da bolsa de estudos durante o desenvolvimento desta pesquisa.

À Universidade Estadual Paulista (UNESP) e ao Programa de Pós-Graduação em Ciências Cartográficas (PPGCC), pela seriedade, qualidade e competência no ensino.

Aos colegas do PPGCC, pelo apoio e bons momentos compartilhados.

Aos professores do Departamento de Cartografia, Matemática e demais, pelo ensino e formação acadêmica.

À Prof<sup>a</sup>. Dr<sup>a</sup>. Arlete Aparecida Correia Meneguette, pela amizade, confiança, ensinamentos compartilhados e por estar presente e me apoiar em momentos importantes da minha vida.

Aos membros da banca de qualificação, Prof. Dr. Erivaldo Antonio da Silva e Prof. Dr. João Lima Sant'anna Neto, pelas valiosas sugestões.

Ao Prof. Dr. João Lima Sant'anna Neto e ao Prof. Dr. Edson Eyji Sano, pelas relevantes contribuições para a concepção do sistema hierárquico de classificação.

Ao Prof. Dr. João Osvaldo Rodrigues Nunes, por fornecer a base vetorial georreferenciada do município de Presidente Prudente (SP).

Ao Instituto Nacional de Pesquisas Espaciais (INPE), pelo fornecimento da imagem TM/Landsat-5, e ao Prof. Dr. Amilton Amorim, pela disponibilização das imagens QuickBird II.

*Noventa por cento do sucesso se baseia simplesmente em insistir.*

*(Woody Allen)*

*Só podemos alcançar um grande êxito quando nos mantemos fiéis a nós mesmos.*

*(Friedrich Nietzsche)*



## RESUMO

Os mapeamentos da cobertura da terra apresentam o relevante papel de permitir avaliar as alterações na paisagem provocadas pela ação antrópica e fornecer importantes informações para o manejo eficiente dos recursos naturais constituindo-se, assim, em ferramentas essenciais para o planejamento regional e urbano. Entretanto, os atuais mapeamentos atendem a propósitos muito específicos e, conseqüentemente, são limitados na sua capacidade de definir a ampla variedade de tipos existentes de cobertura da terra. Nesse contexto, a proposta central desta pesquisa é desenvolver um sistema hierárquico de classificação, amplo e abrangente, partindo de um nível generalizado de definição de classes de cobertura da terra, para mapeamentos em escala regional, e especializando essas classes para ambientes urbanos. Para cada escala de mapeamento é proposta a nomenclatura das classes e os critérios usados para defini-las. Um estudo de caso é desenvolvido para testar o sistema hierárquico em dois níveis de detalhamento distintos, nas escalas regional e urbana, e são utilizadas diferentes abordagens de classificação multiespectral para extrair as informações temáticas de interesse a cada nível de aplicação. Finalmente, é feita a análise da confiabilidade dos mapeamentos temáticos gerados, por meio de coeficientes estatísticos e medidas de incerteza. Os resultados obtidos mostram o sistema hierárquico proposto em três níveis de detalhamento, para escalas de mapeamento distintas, contendo uma ampla variedade de classes com claros critérios de definição, que permite suprir diversas necessidades de mapeamento e possibilita o intercâmbio de informações entre os planejadores e analistas em geral.

**Palavras-chave:** Sistema hierárquico de classificação; sensoriamento remoto; mapeamento temático; cobertura da terra.

## ABSTRACT

*Land cover mappings present the relevant role of allowing to evaluate the changes in the landscape caused by the man's action and to supply important information for the efficient handling of the natural resources. Thus, those are essential tools for the regional and urban planning. However, current mappings are related to very specific purposes and, consequently, they are limited in their capacity to define the wide variety of existent types of land cover. In that context, the main proposal of this research is to develop a wide and including hierarchical classification system, starting from a generalized level of definition of land cover classes for mappings in regional scale and specializing those classes for urban environment. It is proposed the nomenclature of the classes and the criteria used to define them for each scale of mapping. A study case is developed to test the hierarchical system in two detailing levels, in the regional and urban scales, and different approaches of multispectral classification are used to extract the thematic information of interest to each application level. Finally, it is made the analysis of the reliability of the generated thematic mappings, through statistical coefficients and measures of uncertainty. The obtained results show the hierarchical system proposed in three detailing levels, for different mapping scales, containing a wide variety of classes with clear definition criteria, that allows to supply several needs of mapping and makes possible the exchange of information between planners and analysts in general.*

**Keywords:** *Hierarchical classification system; remote sensing; thematic mapping; land cover.*

## LISTA DE FIGURAS

|   |     |
|---|-----|
| Figura 1: Obtenção de informações da superfície terrestre através de sensoriamento remoto.....  | 21  |
| Figura 2: Imagem multiespectral obtida por sensores remotos.....  | 23  |
| Figura 3: Comportamento espectral de alvos característicos de ambientes urbanos. ....   | 27  |
| Figura 4: Diagrama esquemático de uma rede neural artificial com quatro camadas. ....   | 33  |
| Figura 5: Esquema de um neurônio artificial.....  | 34  |
| Figura 6: Partição rígida do espaço multiespectral. ....  | 39  |
| Figura 7: Pertinência de um <i>pixel</i> em uma partição <i>fuzzy</i> do espaço multiespectral. ....  | 40  |
| Figura 8: Sistema hierárquico de classificação com três níveis de detalhamento.....   | 53  |
| Figura 9: Hierarquia de classes para ambientes urbanos, adaptada por Galo, Imai e Ennes (2006).....   | 69  |
| Figura 10: Hierarquia de classes para ambientes urbanos, proposta por Pinho, Kux e Almeida (2007).....  | 70  |
| Figura 11: Localização das áreas de estudo. ....  | 89  |
| Figura 12: Delimitação do município de Presidente Prudente sobre a imagem TM/Landsat-5. ....  | 94  |
| Figura 13: Composição colorida B1G2R3 da imagem multiespectral QuickBird II. ....   | 95  |
| Figura 14: Composição colorida B3G4R5 da imagem TM/Landsat-5 e sobreposição do limite vetorial municipal.....   | 98  |
| Figura 15: Fluxograma das etapas necessárias à classificação relativa bayesiana.....  | 99  |
| Figura 16: Imagens de probabilidade <i>a posteriori</i> para as classes <i>Edificação urbana / rural</i> (A) e <i>Pastagem</i> (B), fornecidas pelo classificador relativo bayesiano..... | 105 |
| Figura 17: Processo de defuzificação a partir das imagens de probabilidade <i>a posteriori</i> ...  | 106 |
| Figura 18: Percentuais de concordância computados para os índices totais de acurácia da classificação em escala regional. ....  | 112 |
| Figura 19: Imagem de incerteza gerada pelo classificador relativo bayesiano.....  | 115 |

|  |     |
|--|-----|
| Figura 20: Representações de áreas com menor e maior graus de incerteza ocorrentes na área de estudo. ....   | 116 |
| Figura 21: Imagens de incerteza para as classes <i>Edificação urbana / rural</i> (A) e <i>Pastagem</i> (B), mapeadas pelo classificador relativo bayesiano. .... | 117 |
| Figura 22: Índice de confusão computado para o classificador relativo bayesiano. ....  | 118 |
| Figura 23: Etapas da técnica de fusão <i>Gram-Schmidt</i> . ....   | 122 |
| Figura 24: Composição colorida B1G2R3 formada com as bandas originais (A) e fusionadas (B). ....   | 123 |
| Figura 25: Imagem de textura de ocorrência por entropia. ....  | 125 |
| Figura 26: Fluxograma das etapas necessárias à classificação pela rede neural artificial. ...  | 127 |
| Figura 27: Médias e desvios-padrão dos dados de treinamento por classe estimados a partir das bandas fusionadas e da informação textural. ....                   | 131 |
| Figura 28: Arquitetura [5-25-18-13] selecionada para a aplicação da rede neural artificial. ....   | 132 |
| Figura 29: Localização dos principais pontos de referência do trecho selecionado da cidade de Presidente Prudente. ....  | 135 |
| Figura 30: Percentuais de concordância computados para os índices totais de acurácia da classificação em escala urbana. ....                                     | 139 |
| Figura 31: Imagens relativas que expressam os graus de pertinência para as classes <i>Outros</i> (A) e <i>Árvore / Arbusto</i> (B). ....                         | 141 |
| Figura 32: Imagens de incerteza para as classes <i>Outros</i> (A) e <i>Árvore / Arbusto</i> (B), mapeadas pelo classificador por rede neural artificial. ....    | 142 |
| Figura 33: Saídas relativas para a classe <i>Cerâmica</i> , sem a informação de textura (A) e com o uso dessa informação (B). ....                               | 144 |
| Figura 34: Imagem de incerteza gerada a partir das saídas relativas fornecidas pela classificação pela rede neural artificial. ....                              | 145 |

## LISTA DE TABELAS

|   |     |
|---|-----|
| Tabela 1: Características das imagens TM/Landsat-5. ....  | 24  |
| Tabela 2: Características das imagens Quickbird II.....   | 25  |
| Tabela 3: Estrutura da matriz de erros (ou de confusão).....  | 46  |
| Tabela 4: Qualidade do mapa temático associada aos valores da estatística <i>Kappa</i> .....  | 47  |
| Tabela 5: Caracterização de programas de cartografia do uso e cobertura da terra.....   | 56  |
| Tabela 6: Sistema desenvolvido por Anderson et al. (1976) e utilizado pelo USGS.....  | 59  |
| Tabela 7: Instrumentos sensores e resoluções espaciais recomendadas para o mapeamento dos níveis propostos por Anderson et al. (1976). .... | 60  |
| Tabela 8: Sistema proposto pelo projeto CORINE <i>Land Cover</i> . ....   | 61  |
| Tabela 9: Procedimento de mapeamento definido no Manual Técnico de Uso da Terra. ....   | 63  |
| Tabela 10: Classes, tipos e subtipos de uso da terra.....   | 64  |
| Tabela 11: Sistema proposto no Projeto de Uso da Terra do IBGE.....   | 65  |
| Tabela 12: Esquema da classificação das Regiões Fitoecológicas brasileiras.....   | 67  |
| Tabela 13: Classes de cobertura da terra urbana propostas por Souza et al. (2003). ....   | 70  |
| Tabela 14: Sistema hierárquico de classificação para o mapeamento da cobertura da terra em escala regional.....                             | 73  |
| Tabela 15: Sistema hierárquico de classificação para o mapeamento da cobertura da terra em escala urbana. ....                              | 86  |
| Tabela 16: Chave de interpretação dos alvos da imagem TM/Landsat-5. ....  | 100 |
| Tabela 17: Melhores índices de separabilidade média obtidos pela medida de divergência transformada. ....                                   | 103 |
| Tabela 18: Matriz de partição <i>fuzzy</i> .....  | 104 |
| Tabela 19: Proporção de ocorrência estimada para as classes do mapeamento em escala regional.....   | 108 |
| Tabela 20: Matriz de erros gerada pela classificação em escala regional. ....   | 110 |

|  |     |
|--|-----|
| Tabela 21: Índices de exatidão por classe computados para o mapeamento em escala regional.....                   | 113 |
| Tabela 22: Parâmetros estatísticos calculados para os dados originais e fusionados por diferentes técnicas. .... | 121 |
| Tabela 23: Chave de interpretação dos alvos da imagem Quickbird II fusionada.....                                | 128 |
| Tabela 24: Proporção de ocorrência estimada para as classes do mapeamento em escala urbana. ....                 | 134 |
| Tabela 25: Matriz de erros gerada pela classificação em escala urbana. ....                                      | 138 |
| Tabela 26: Índices de exatidão por classe computados para o mapeamento em escala urbana. ....                    | 139 |
| Tabela 27: Sistema hierárquico de classificação para o mapeamento do uso da terra em escala urbana. ....         | 147 |

## SUMÁRIO

|          |  |           |
|----------|--|-----------|
| <b>1</b> | <b>INTRODUÇÃO .....</b>  | <b>15</b> |
| 1.1      | CONSIDERAÇÕES INICIAIS.....  | 15        |
| 1.2      | OBJETIVOS .....  | 17        |
| 1.3      | JUSTIFICATIVA .....  | 18        |
| 1.4      | ESTRUTURA DA DISSERTAÇÃO.....  | 19        |
| <b>2</b> | <b>SENSORIAMENTO REMOTO E CONCEITOS FUNDAMENTAIS .....</b>                       | <b>21</b> |
| 2.1      | SATÉLITES E SISTEMAS SENSORES .....  | 23        |
| 2.2      | COMPORTAMENTO ESPECTRAL DE ALVOS .....   | 26        |
| <b>3</b> | <b>EXTRAÇÃO DE INFORMAÇÕES A PARTIR DE IMAGENS DE SENSORIAMENTO REMOTO .....</b> | <b>28</b> |
| 3.1      | PRÉ-PROCESSAMENTOS DE IMAGENS ORBITAIS.....                                      | 28        |
| 3.2      | CLASSIFICAÇÃO DE IMAGENS MULTIESPECTRAIS.....                                    | 30        |
| 3.2.1    | Classificação por redes neurais artificiais .....                                | 32        |
| 3.2.2    | Classificação baseada em abordagem <i>fuzzy</i> .....                            | 37        |
| 3.3      | CONFIABILIDADE DO MAPEAMENTO .....   | 42        |
| 3.3.1    | Estimativas de acurácia baseada em coeficientes estatísticos .....               | 43        |
| 3.3.2    | Análise da incerteza.....  | 49        |
| <b>4</b> | <b>SISTEMAS DE CLASSIFICAÇÃO DE USO E COBERTURA DA TERRA .....</b>               | <b>52</b> |
| 4.1      | SISTEMAS DE CLASSIFICAÇÃO PARA MAPEAMENTO EM ESCALA REGIONAL .....               | 56        |
| 4.1.1    | Sistema utilizado pelo Serviço Geológico dos Estados Unidos (USGS) .....         | 58        |
| 4.1.2    | Sistema proposto pelo Projeto CORINE <i>Land Cover</i> .....                     | 60        |
| 4.1.3    | Sistema proposto pelo Projeto de Uso da Terra do IBGE .....                      | 62        |
| 4.1.4    | Sistema apresentado no Manual Técnico da Vegetação Brasileira .....              | 66        |
| 4.2      | SISTEMAS DE CLASSIFICAÇÃO PARA MAPEAMENTO EM ESCALA URBANA .....                 | 68        |
| <b>5</b> | <b>PROPOSTA DO SISTEMA HIERÁRQUICO DE CLASSIFICAÇÃO .....</b>                    | <b>72</b> |
| 5.1      | PROPOSTA DO SISTEMA HIERÁRQUICO PARA ESCALA REGIONAL .....                       | 72        |
| 5.2      | PROPOSTA DO SISTEMA HIERÁRQUICO PARA ESCALA URBANA .....                         | 85        |
| <b>6</b> | <b>APLICAÇÃO DO SISTEMA HIERÁRQUICO DE CLASSIFICAÇÃO.....</b>                    | <b>88</b> |
| 6.1      | CARACTERIZAÇÃO DAS ÁREAS DE ESTUDO.....  | 88        |
| 6.2      | ESPECIFICAÇÃO DOS PROJETOS DE CLASSIFICAÇÃO .....                                | 90        |
| 6.2.1    | Projeto para mapeamento em escala regional.....                                  | 90        |
| 6.2.2    | Projeto para mapeamento em escala urbana.....                                    | 92        |
| 6.3      | MATERIAL UTILIZADO .....   | 93        |
| 6.4      | PROCESSAMENTOS E ANÁLISES DO MAPEAMENTO EM ESCALA REGIONAL .....                 | 96        |
| 6.4.1    | Pré-processamentos dos dados .....   | 97        |
| 6.4.2    | Extração e representação da informação temática.....                             | 98        |
| 6.4.3    | Análise da confiabilidade do mapeamento.....                                     | 109       |

|          |  |            |
|----------|--|------------|
| 6.5      | PROCESSAMENTOS E ANÁLISES DO MAPEAMENTO EM ESCALA URBANA .....               | 119        |
| 6.5.1    | Pré-processamentos dos dados .....   | 119        |
| 6.5.2    | Extração e representação da informação temática.....                         | 126        |
| 6.5.3    | Análise da confiabilidade do mapeamento.....                                 | 137        |
| 6.5.4    | Adequação das classes de cobertura propostas a classes de uso da terra ..... | 145        |
| <b>7</b> | <b>CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES .....</b>                            | <b>148</b> |
| 7.1      | CONSIDERAÇÕES FINAIS .....   | 148        |
| 7.2      | RECOMENDAÇÕES .....  | 150        |
|          | <b>REFERÊNCIAS .....</b>   | <b>152</b> |
|          | <b>APÊNDICE A .....</b>  | <b>165</b> |
|          | <b>APÊNDICE B.....</b>   | <b>167</b> |



# 1 INTRODUÇÃO

## 1.1 Considerações iniciais

Nas últimas décadas, os sistemas de sensoriamento remoto têm sido amplamente utilizados no mapeamento da cobertura terrestre e no monitoramento dos recursos naturais. Isto se deve ao fato de que os dados obtidos a partir de satélites propiciam coberturas repetitivas da superfície terrestre em intervalos de tempo relativamente curtos. Destaca-se também a possibilidade de processamento rápido desses dados através de técnicas de análise associadas a sistemas computacionais (VILELA et al., 2000).

Dessa forma, os dados de sensores remotos precisam ser analisados para possibilitar a extração de informações necessárias ao planejamento, manejo e monitoramento dos recursos. Essa análise torna-se viável pelo fato dos alvos da superfície terrestre apresentarem comportamentos específicos ao longo do espectro eletromagnético, os quais podem, portanto, ser usados para identificá-los (JENSEN, 1996).

A extração de informações a partir desses dados orbitais implica na necessidade de uma forma de representação que seja assimilável pelo usuário. Para tanto, convencionalmente, são utilizados mapeamentos temáticos, onde os alvos da superfície terrestre, detectados pelos sensores remotos, são caracterizados e associados a classes (ou categorias) temáticas que definem o uso e a cobertura da terra. Esses mapeamentos, gerados principalmente através de técnicas de classificação multiespectral, têm se tornado cada vez mais frequentes devido à grande quantidade de imagens disponíveis geradas por satélites com as mais variadas resoluções.

Dentre as técnicas de classificação multiespectral, as convencionais por *pixel* e por regiões ainda são amplamente utilizadas, principalmente por usuários não especialistas. Contudo, outras técnicas menos usuais têm se mostrado mais satisfatórias e, assim, se tornado preferenciais, tais como classificações baseadas em abordagem *fuzzy* ou por redes neurais artificiais.

Canters (1997), Foody (1992), Wang (1990) e outros pesquisadores afirmam que a teoria de conjuntos *fuzzy* pode contribuir para uma melhor representação dos fenômenos geográficos. Uma classificação baseada em abordagem *fuzzy* permite caracterizar a transição



entre tipos de uso e cobertura terrestre e lidar com a ocorrência de *pixels* mistos, muito frequentes, principalmente, em imagens resolução espacial métrica e quilométrica.

Por sua vez, a utilização de modelos de redes neurais artificiais em classificação possibilita a incorporação não apenas de dados multiespectrais, mas de dados adquiridos por outras fontes, que não apresentem natureza espectral. Nessas situações, as redes neurais artificiais parecem desempenhar a tarefa de classificação de imagens tão bem, ou melhor, que as técnicas estatísticas, uma vez que não requerem que a natureza paramétrica dos dados a serem classificados seja explicitada (LEE et al., 1990).

Independente da técnica utilizada, uma classificação requer, previamente, a definição dos tipos de classes de interesse e de seus critérios, os quais devem ser claros e objetivos. Contudo, o que se vê, atualmente, é uma grande quantidade de mapeamentos temáticos com classes inapropriadas para propósitos particulares, ou com terminologia ambígua, voltados a finalidades específicas, ou com informação, muitas vezes, obsoleta (DI GREGÓRIO, 2004).

Normalmente, cada usuário define sua própria legenda da classificação, contendo as classes de uso e cobertura da terra necessárias a sua aplicação. Assim, ainda que a nomenclatura das classes seja similar, em alguns casos, nem sempre as definições dos critérios para as classes são as mesmas.

Apesar da necessidade de um sistema de classificação padrão, nenhuma das classificações atuais é internacionalmente aceita. Em geral, o que se encontra na literatura são classificações de vegetação ou sistemas relacionados à descrição de alvos específicos (por exemplo, áreas agrícolas ou fisionomias vegetacionais), os quais são, portanto, limitados na sua capacidade de definir toda a variedade de tipos possíveis de cobertura da terra (DI GREGÓRIO, 2004).

Uma das principais contribuições na literatura, no sentido de um sistema amplo e abrangente, refere-se ao trabalho elaborado por Anderson et al. (1976), os quais desenvolveram, na década de 70, o sistema utilizado pelo Serviço Geológico dos Estados Unidos (USGS) para a geração de mapas do território americano. Desde então, vários outros sistemas foram propostos, contudo, ainda assim, independentes e específicos às suas regiões e a um determinado propósito.

Outro sistema que constitui uma referência teórica é o proposto pelo Projeto CORINE (Coordenação de Informação do Ambiente) *Land Cover*, definido na década de 80 para o mapeamento de terras européias. Esse sistema de classificação possui uma hierarquia



de classes que pode ser útil a diferentes projetos de mapeamento, atendendo à demanda de diferentes usuários.

No Brasil, a iniciativa de definição de um sistema de classificação nacional está restrita ao IBGE (Instituto Brasileiro de Geografia e Estatística), através do Projeto de Uso da Terra, estabelecido no final da década de 90 com vistas a sistematizar as informações sobre o meio ambiente.

Dessa forma, dentre muitos sistemas de classificação existentes, cada qual proposto por uma entidade responsável e voltado a uma finalidade específica, o sistema utilizado pelo USGS continua sendo a principal referência teórica, acompanhado, desde épocas mais recentes, pelo sistema europeu do Projeto CORINE *Land Cover*. Ambos privilegiam um sistema voltado para a caracterização da cobertura da terra. Por outro lado, a proposição teórica brasileira, recentemente melhorada e atualizada, tem como foco principal a classificação do uso da terra.

## 1.2 Objetivos

Esta pesquisa tem por objetivo principal desenvolver um sistema hierárquico de classificação, amplo e abrangente, partindo de um nível generalizado de definição de classes de cobertura da terra, para mapeamentos em escala regional, e especializando essas classes para aplicações em ambientes urbanos.

Nesse contexto, são definidos os seguintes objetivos específicos:

- propor uma hierarquia de classes em diferentes níveis de detalhamento, estabelecendo a nomenclatura e os critérios de definição dessas classes;
- desenvolver um estudo de caso específico para testar o sistema hierárquico nas escalas regional e urbana;
- analisar a qualidade da informação temática produzida.



### 1.3 Justificativa

O mapeamento da cobertura terrestre apresenta o relevante papel de permitir avaliar as alterações provocadas pela ação antrópica e fornecer importantes informações para o manejo eficiente dos recursos naturais constituindo, assim, uma ferramenta para o planejamento regional e urbano. Em outras palavras, através do mapeamento da cobertura e do uso da terra, pode-se identificar e monitorar as atividades preponderantes, inadequadas e conflitivas da região em estudo, o que poderá auxiliar os planejadores na elaboração de projetos setoriais de uso do solo, na localização de atividades diversas e nos zoneamentos em geral.

Dessa forma, é notável a importância de mapeamentos da superfície terrestre, no sentido de contribuir para o conhecimento de cada território. Dentro disso, os sistemas de classificação exercem um papel fundamental no estabelecimento de uma hierarquia de classes que satisfaça às necessidades de planejadores e analistas em geral, permitindo identificar e mapear informações de interesse.

Nesse contexto, a idéia de um sistema de classificação amplo e abrangente é fundamental, por exemplo, para possibilitar o intercâmbio de informações entre usuários, utilizando a mesma nomenclatura para as classes e critérios únicos na sua definição. Na ausência de uma padronização, pode haver a duplicação de esforços decorrente da repetição de trabalhos por diferentes usuários, desnecessária quando há a possibilidade de interação entre os mesmos.

Além disso, um sistema de classificação, em especial, hierárquico, permite uma organização adequada das classes de interesse, condizente com a estruturação da paisagem, isto é, com a estrutura hierárquica dos geossistemas.

Dessa forma, acredita-se que esforços são necessários no sentido de contribuir com o desenvolvimento de um sistema de classificação que atenda à demanda não apenas de usuários específicos, mas sim que seja amplo e consistente. Essa não é uma tarefa trivial diante da diversidade de tipos existentes de cobertura terrestre, cada qual influenciado pelas características locais da região na qual se encontra. Parte-se, então, do pressuposto que uma hierarquia de classes mais generalizada pode ser definida, a partir da qual será especializada para aplicações particulares.



## 1.4 Estrutura da dissertação

Esta dissertação está estruturada em sete capítulos. No Capítulo 1, é delineado o assunto a ser tratado e os objetivos gerais e específicos, além das considerações e justificativas que sustentam o tema proposto.

O Capítulo 2 traz uma revisão sobre conceitos necessários ao desenvolvimento da pesquisa. Em tópicos distintos, são descritos o processo de sensoriamento remoto para a aquisição de imagens multiespectrais; os tipos de resolução considerados para essas imagens; os sistemas sensores utilizados; e a importância do conhecimento do comportamento espectral de alvos para a geração de mapeamentos.

No Capítulo 3, é descrito o processo de extração de informações a partir de imagens orbitais, o qual é composto de três etapas distintas e complementares: pré-processamentos, que visam a melhoria dos dados para interpretação visual e processamentos via computador; classificação multiespectral, utilizada para a extração de informações de imagens orbitais, com destaque para as técnicas de classificação baseada em abordagem *fuzzy* e por rede neural artificial; e análise da confiabilidade do mapeamento, que permite avaliar a qualidade da informação representada.

O Capítulo 4 aborda o estado da arte em sistemas de classificação de uso e cobertura da terra, descrevendo as principais referências teóricas para o mapeamento em escala regional: os sistemas propostos por Anderson et al. (1976) e pelo Projeto CORINE *Land Cover*, no contexto internacional, além do sistema proposto pelo Projeto de Uso da Terra elaborado pelo IBGE, em escala nacional. Para o mapeamento em escala urbana, são descritos os trabalhos de maior destaque encontrados na literatura, que fornecem subsídios para a formulação do sistema proposto nesta pesquisa.

O Capítulo 5 apresenta a proposta para o sistema hierárquico de classificação nas escalas regional e urbana, onde são descritas a nomenclatura das classes e os critérios utilizados para defini-las. Esse sistema é proposto em três níveis de detalhamento, tanto para o mapeamento regional quanto urbano, e uma breve discussão é feita a respeito de recomendações quanto ao tipo de sensor e característica dos dados adequados para o mapeamento em cada nível hierárquico.

No Capítulo 6, são descritas as aplicações do sistema de classificação para os mapeamentos regional e urbano. Para cada aplicação, é definido um projeto de classificação específico contemplando a área de estudo selecionada, os dados e as técnicas de



extração de informação recomendadas, bem como a forma de análise da qualidade da informação temática produzida. Além disso, é feita uma descrição detalhada da metodologia utilizada para os processamentos e análises necessários a cada aplicação. Especificamente para a escala urbana, ainda é apresentada uma breve discussão no sentido de adequar as classes de cobertura propostas a classes de uso da terra.

Finalmente, no Capítulo 7, constam as considerações finais da pesquisa, face aos objetivos propostos e, com base na experiência adquirida, são feitas recomendações no sentido de aprofundar alguns assuntos específicos pesquisados e sugestões para investigações futuras.



## 2 SENSORIAMENTO REMOTO E CONCEITOS FUNDAMENTAIS

Como a visão humana, é limitada é necessário buscar uma abordagem alternativa que permita registrar, quantificar e fornecer, adequadamente, informações sobre os objetos estudados. Nesse contexto, o sensoriamento remoto surge como uma tecnologia que permite suprir essa necessidade.

Conforme Lillesand, Kiefer e Chipman (2004), o sensoriamento remoto é a ciência e a arte de se obter informações sobre um determinado alvo (objetos, áreas ou fenômenos), através da análise dos dados adquiridos por meio de um sensor que não esteja em contato com o alvo sob investigação. Um sistema de sensoriamento remoto que utiliza energia eletromagnética para adquirir e registrar informações da superfície terrestre pode ser visualizado na Figura 1, onde são destacados quatro componentes básicos: a fonte de energia (normalmente, o Sol, para sistemas passivos<sup>1</sup>); a atmosfera; os alvos terrestres; e o satélite/sensor.




Figura 1: Obtenção de informações da superfície terrestre através de sensoriamento remoto.  
Fonte: Adaptado de FLORENZANO (2002).

<sup>1</sup> Os sensores passivos não possuem radiação própria, isto é, não emitem energia, mas captam a energia refletida e/ou emitida pelos alvos (MOREIRA, 2001).



A radiação eletromagnética (REM) que é emitida pela fonte se propaga pela atmosfera até atingir os alvos da superfície terrestre. Contudo, os componentes atmosféricos (gás carbônico, oxigênio, ozônio, vapor d'água e aerossóis) interferem no percurso da REM até os alvos, podendo ocasionar efeitos de absorção e espalhamento dessa energia (LILLESAND; KIEFER; CHIPMAN, 2004).

A energia que, efetivamente, é emitida pela fonte e que incide sobre a superfície de um alvo pode ocasionar três tipos básicos de interações: reflexão, absorção e transmissão. A proporção desses mecanismos varia para diferentes alvos terrestres, dependendo do tipo e condição do material e do comprimento de onda da radiação incidente (LILLESAND; KIEFER; CHIPMAN, 2004).

Após percorrer o trajeto da fonte até os alvos terrestres, a energia refletida e/ou emitida pela superfície é captada por dispositivos eletrônicos (sensores), instalados em satélites artificiais, e transformada em sinais elétricos, que são registrados e transmitidos para estações de recepção na Terra (Figura 1). Esses sinais recebidos pelas estações são transformados em dados na forma de gráficos, tabelas ou imagens, que, quando interpretados, permitem obter informações a respeito dos alvos da superfície terrestre (FLORENZANO, 2002).

As imagens obtidas por sistemas sensores, ditas multiespectrais, constituem um conjunto de cenas (denominadas canais ou bandas) adquiridas, simultaneamente, de uma mesma área, onde a REM é registrada em diferentes intervalos espectrais. Essas imagens são armazenadas como matrizes, onde cada elemento (denominado *pixel*) que as constitui possui coordenadas espaciais ( $x$ ,  $y$ ) e é representado por um conjunto de valores de brilho (tons de cinza ou níveis digitais). Assim, cada *pixel* pode ser representado por um vetor de atributos, cuja dimensão é definida pela quantidade de bandas espectrais analisadas (RICHARDS; JIA, 1999). A Figura 2 ilustra uma imagem multiespectral, onde  $x$  e  $y$  definem as coordenadas espaciais do *pixel* e  $n$  é o vetor que representa as  $M$  bandas espectrais.






Figura 2: Imagem multiespectral obtida por sensores remotos.  
Fonte: Adaptado de Richards e Jia (1999).

A aquisição de dados de sensoriamento remoto, com aplicação em recursos naturais, tem sido feita através de diferentes tipos de sensores, desde a década de 1970, com o lançamento do primeiro satélite Landsat. Com o passar dos anos, muitos outros sistemas surgiram, cada qual voltado para finalidades específicas e possuindo características particulares.

## 2.1 Satélites e sistemas sensores

Segundo Novo (1992), os diferentes sistemas sensores são caracterizados por sua resolução, que é definida como a medida da habilidade que o sensor possui para discernir entre respostas espectralmente semelhantes e espacialmente próximas. Além da resolução espacial, que mede a menor separação linear (ou angular) entre dois objetos da superfície terrestre, os sistemas de varredura dos satélites podem ser caracterizados pela resolução espectral, a qual é definida como a medida da largura e do número de bandas espectrais nas quais opera o sensor; resolução radiométrica, relacionada com a sensibilidade do sensor em diferenciar dois níveis de intensidade do sinal de retorno; e resolução temporal, que se refere ao intervalo de tempo entre a aquisição de duas imagens de uma mesma área.

Em função da resolução espacial, sugere-se classificar os sistemas sensores como sendo de resolução centimétrica, métrica ou quilométrica. Essa sugestão é interessante, visto que não existe um consenso na literatura entre os autores e cada qual costuma classificar os sistemas sensores de uma maneira diferente.

### – **Satélite Landsat-5**

A série de satélites Landsat (*Land Remote Sensing Satellite* ou Satélite de sensoriamento remoto da Terra) foi iniciada no final da década de 60, a partir de um projeto desenvolvido pela Agência Espacial Americana dedicado, exclusivamente, à observação dos recursos naturais terrestres. O primeiro satélite da série começou a operar em 1972 e a última atualização ocorreu em 1999, com o lançamento do Landsat-7 (NOVO, 1992).

Atualmente, o único satélite em operação é o Landsat-5, lançado em março de 1984, que leva a bordo os sensores MSS (*Multispectral Scanner*) e TM (*Thematic Mapper*). Dentre esses sensores, destaque pode ser dado ao TM, o qual fornece imagens multiespectrais adquiridas nos intervalos de comprimento de onda do visível ao infravermelho termal. As características dessas imagens são apresentadas na Tabela 1.

Tabela 1: Características das imagens TM/Landsat-5.

| <i>Região Espectral</i> | <i>Intervalo Espectral</i> | <i>Resolução Espacial</i> |
|-------------------------|----------------------------|---------------------------|
| Luz Azul                | 0,45 – 0,52 $\mu\text{m}$  | 30 m                      |
| Luz Verde               | 0,52 – 0,60 $\mu\text{m}$  |                           |
| Luz Vermelha            | 0,63 – 0,69 $\mu\text{m}$  |                           |
| Infravermelho Próximo   | 0,76 – 0,90 $\mu\text{m}$  |                           |
| Infravermelho Médio     | 1,55 – 1,75 $\mu\text{m}$  |                           |
| Infravermelho Termal    | 10,4 – 12,5 $\mu\text{m}$  | 120 m                     |
| Infravermelho Médio     | 2,08 – 2,35 $\mu\text{m}$  | 30 m                      |

Fonte: Adaptado de Jensen (1996).

O satélite Landsat-5 possui resolução temporal de 16 dias, e o sensor TM apresenta resolução radiométrica de 8 bits (256 níveis de cinza) e imageia uma faixa de 185 km x 185 km na superfície terrestre. Apesar de se tratar de um satélite ainda muito usual na área de cartografia e outras, se encontra ativo há mais de vinte anos, ultrapassando o tempo de vida útil esperado.

### – **Satélite QuickBird II**

O QuickBird II é o primeiro satélite comercial de sensoriamento remoto a produzir imagens com resolução espacial centimétrica, o qual foi lançado em outubro de



2001, na Califórnia, Estados Unidos (DIGITALGLOBE, 2006). Esse satélite constitui um sistema americano e foi concebido pelas empresas *DigitalGlobe*, *Ball Aerospace & Technologies Corp.*, *Kodak* e *Fokker Space*, cada qual responsável pela construção de uma parte do sistema (KUX; PINHEIRO, 2005).

O satélite QuickBird II possui sensores CCD (*Charge Coupled Device*) que realizam a varredura eletrônica em fileira linear (*pushbroom linear array*), os quais são flexíveis para visadas *off-nadir* até 30°, ao longo do terreno imageado, possibilitando obter pares de imagens com estereoscopia, com condições de iluminação e geometria do satélite igual para ambas as imagens.

Esse satélite possui resolução temporal de 1 a 3,5 dias (conforme a latitude) e seus sensores fornecem imagens multiespectrais e pancromáticas coletadas com 11 bits (2.048 níveis de cinza) de resolução radiométrica. As imagens multiespectrais abrangem o intervalo espectral do visível ao infravermelho próximo, com resolução espacial variando de 2,44 a 2,88 m, enquanto as imagens pancromáticas apresentam resolução espacial de 0,61 a 0,72 m, proporcionando maior visibilidade na interpretação visual dos alvos presentes na superfície terrestre. A Tabela 2 apresenta um resumo das características das imagens QuickBird II.

Tabela 2: Características das imagens QuickBird II.

| <i>Imagem</i>  | <i>Região Espectral</i> | <i>Intervalo Espectral</i> | <i>Resolução Espacial</i>                                   |
|----------------|-------------------------|----------------------------|---|
| Multiespectral | Luz Azul                | 0,45 – 0,52 $\mu\text{m}$  | 2,44 m ( <i>nadir</i> ) e<br>2,88 m (25° <i>off-nadir</i> ) |
|                | Luz Verde               | 0,52 – 0,60 $\mu\text{m}$  |   |
|                | Luz Vermelha            | 0,63 – 0,69 $\mu\text{m}$  |   |
|                | Infravermelho Próximo   | 0,76 – 0,90 $\mu\text{m}$  |   |
| Pancromática   | Pancromática            | 1,55 – 1,75 $\mu\text{m}$  | 0,61 m ( <i>nadir</i> ) e<br>0,72 m (25° <i>off-nadir</i> ) |

Fonte: Adaptado de DigitalGlobe (2006).

A resolução espacial das imagens, proporcionada por esse sensor, depende do ângulo de visada de imageamento, podendo ser no *nadir* ou *off-nadir*, conforme a Tabela 2. Quando o ângulo de visada *off-nadir* aumenta, há uma degradação da resolução espacial e, conseqüentemente, ocorre o aumento da área imageada, permitindo ao usuário obter cenas do terreno com maior frequência e com estereoscopia, tanto para as imagens pancromáticas quanto multiespectrais.

A DigitalGlobe comercializa as imagens QuickBird II, basicamente, com três níveis de tratamento: Imagens Básicas (*Basic Imagery*), Imagens Padrão (*Standard Imagery*) e Imagens Ortoretificadas (*Orthorectified Imagery*). As Imagens Básicas



apresentam correções radiométricas e de distorções do sensor, mas não são corrigidas geometricamente. As Imagens Padrão apresentam as mesmas correções mencionadas anteriormente e também possuem correção geométrica, sendo associadas a um sistema de projeção cartográfica. As Imagens Ortoretificadas passam por diversas etapas de processamentos para correção radiométrica, geométrica e do sensor, ortoretificação<sup>2</sup> e mudança de projeção e *datum* (DIGITALGLOBE, 2006).

## 2.2 Comportamento espectral de alvos

Os alvos da superfície terrestre possuem diferentes características espectrais, podendo ser identificados pelo seu comportamento espectral (ou assinatura espectral). O conhecimento do comportamento espectral dos alvos é importante tanto para a extração de informações das imagens multiespectrais, quanto para a própria definição de novos sensores, seleção do tipo de processamento a que devem ser submetidos os dados brutos e definição da forma de aquisição desses dados (geometria de coleta, frequência, altura do imageamento, resolução limite etc.) (NOVO, 1992).

A assinatura espectral dos alvos é, normalmente, representada por um gráfico que relaciona a porcentagem de reflectância do alvo em função do comprimento de onda ( $\mu\text{m}$ ), como ilustra a Figura 3, para diferentes tipos de alvos característicos de ambientes urbanos. A partir de um conjunto de valores de reflectância para o mesmo alvo, medido em um intervalo específico de comprimento de onda, supõe-se conhecido o comportamento espectral daquele alvo (JENSEN, 2000).

---

<sup>2</sup> Para realizar a ortoretificação das imagens é necessária a utilização de um modelo digital do terreno (MDT) e/ou pontos de controle, para que seja feita a remoção do deslocamento da imagem devido à inclinação e efeito do relevo (DIGITALGLOBE, 2006).



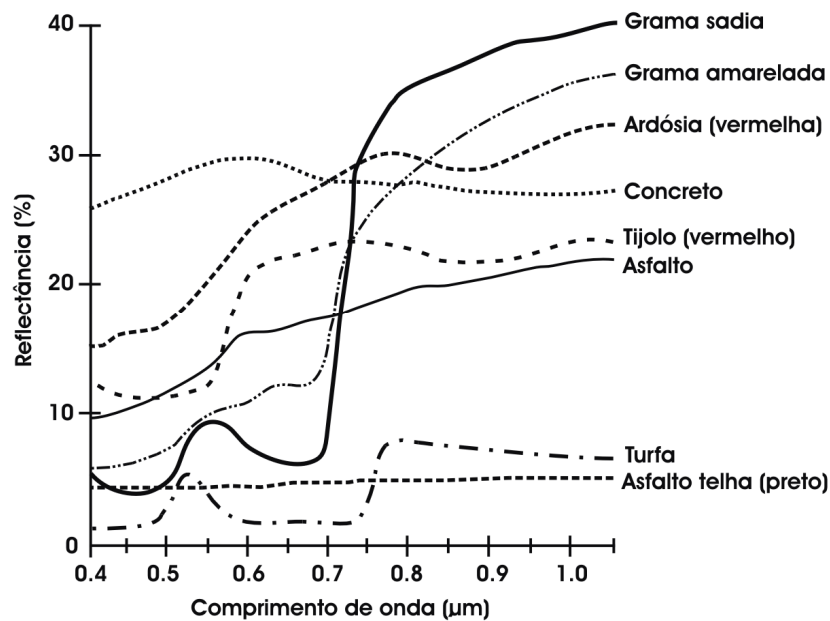


Figura 3: Comportamento espectral de alvos característicos de ambientes urbanos.

Fonte: Adaptado de Jensen (2000).

Como pode ser observado na Figura 3, certos intervalos de comprimento de onda proporcionam baixa separabilidade entre alguns tipos de alvos em decorrência das assinaturas espectrais desses alvos serem, aproximadamente, semelhantes nessas regiões. Por outro lado, outras regiões espectrais favorecem a discriminação desses alvos. Assim, é fundamental que o analista conheça o comportamento espectral dos alvos de interesse a sua aplicação, previamente ao processo de extração de informações.

As curvas de reflectância que caracterizam o comportamento espectral de alvos são curvas médias fornecidas por pesquisas, que apontam o que se espera obter para a assinatura espectral dos alvos em condições normais. Contudo, deve-se estar ciente da variabilidade dessas assinaturas, visto que estas não podem ser consideradas como um padrão que é absoluto e único (LILLESAND; KIEFER; CHIPMAN, 2004). Vários são os fatores que podem influenciar nas medidas de reflectância dos alvos, pois estes estão inseridos num contexto ambiental sofrendo, portanto, interferências múltiplas, seja dos alvos adjacentes ou oriundas do próprio dinamismo interno de suas características (NOVO, 1992).

Informações mais detalhadas a respeito do comportamento espectral de alvos como vegetação, solo, água e alvos urbanos podem ser obtidas em Novo (1992), Jensen (2000) e Moreira (2001).

### 3 EXTRAÇÃO DE INFORMAÇÕES A PARTIR DE IMAGENS DE SENSORIAMENTO REMOTO

Jensen (2000) afirma que pesquisas aplicadas na área de sensoriamento remoto estão embasadas, normalmente, no chamado método científico – uma forma de pensar sobre problemas e resolvê-los. Esse método implica na execução de cinco etapas distintas e integradas: 1) declaração de um problema; 2) formulação de uma hipótese; 3) observação e experimentação; 4) interpretação de dados; e 5) apresentação dos resultados.

Assim, o processo de extração de informações a partir do sensoriamento remoto consiste, inicialmente, em observar um problema e lançar uma hipótese a respeito, ou seja, uma possível explicação. A partir disso, faz-se a coleta dos dados (ex.: imagens orbitais) necessários à experimentação. Esses dados precisam ser convertidos em informação, normalmente, através de técnicas de processamentos digitais. Com isso, pode-se testar a hipótese previamente formulada e apresentar os resultados obtidos (JENSEN, 2000). Assim, para que a hipótese do trabalho possa ser avaliada é preciso dispor de dados tratados e, a partir disso, são extraídas as informações para análise.

#### 3.1 Pré-processamentos de imagens orbitais

As técnicas de pré-processamento de imagens orbitais visam a melhoria dos dados para interpretação visual humana, bem como para o processamento dos dados via computador. A função chave nesse processo é melhorar a imagem de forma a aumentar as chances para o sucesso dos processamentos seguintes (GONZALEZ; WOODS, 2000).

Conforme Fonseca (2000), as imagens orbitais contêm distorções que devem ser corrigidas antes de serem utilizadas nas aplicações. Embora alguns tipos de distorções sejam corrigidos, previamente, na estação de recepção das imagens, há ainda a necessidade de se realizar algumas correções antes da fase de extração de informação. A etapa de correção dessas distorções constitui um dos pré-processamentos mais importantes.

A correção radiométrica de imagens orbitais visa converter os números digitais dos *pixels* em unidades de reflectância, eliminando os fatores que alteram a reflectância dos alvos, tais como distorções na calibração dos detectores do sistema sensor e



influências atmosféricas (JENSEN, 1996). Alguns autores consideram que esse tipo de correção em cartografia temática, na prática, é aconselhável para mapeamentos em áreas de relevo acentuado e em estudos multitemporais que envolvam a comparação direta entre imagens adquiridas em épocas distintas (CAETANO; SANTOS; GONÇALVES, 2002).

Por outro lado, técnicas de correção geométrica são normalmente utilizadas para corrigir erros devido à curvatura da Terra e do terreno imageado, à inclinação do eixo de rotação da Terra e a diferentes forças centrífugas que afetam o movimento da plataforma, além dos erros provenientes do próprio sistema de sensoriamento remoto, incluindo distorções sistemáticas (STEIN et al., 1999). Dentre as técnicas existentes, o georreferenciamento (ou registro)<sup>3</sup> é a mais usual, na qual são utilizadas funções polinomiais que permitem estabelecer relações matemáticas entre as localizações de *pixels* em uma imagem e as coordenadas correspondentes desses pontos na superfície terrestre, através da utilização de pontos de controle (PCs). Os PCs são obtidos por meio de sistemas de posicionamento por satélites (GPS, GLONASS etc.), métodos topográficos, ou, ainda, obtidos diretamente sobre um documento cartográfico georreferenciado. O desempenho da correção geométrica, nesse caso, irá depender da quantidade e da qualidade dos PCs, os quais devem ser bem definidos e bem distribuídos sobre a imagem a ser georreferenciada (CROITORU et al., 2004).

Em muitos estudos, para melhorar a extração de informações, o analista realiza operações de transformação de bandas espectrais. Essas operações incluem, por exemplo, análise de componentes principais; geração de índices de vegetação; aplicação de filtros espaciais; geração de imagens de textura; dentre outras. Cada uma dessas operações produz uma nova imagem ou um novo conjunto de imagens a partir do conjunto de dados originais, que pode ser utilizado para melhorar a extração de determinados alvos de interesse.

Operações de ampliação de contraste e geração de composições coloridas também são constantemente utilizadas, a fim de facilitar a interpretação visual dos alvos da cena. Geralmente, as imagens de sensoriamento remoto tendem a ser escuras e apresentar baixo contraste, em especial as bandas adquiridas no intervalo do visível, cujos comprimentos de onda são os que mais sofrem interferência dos efeitos atmosféricos. Dessa forma, operações de contraste são uma alternativa que permite expandir a variabilidade dos valores de brilho representativos de uma imagem, melhorando o seu contraste, bem como aumentar os valores de brilho da cena.

---

<sup>3</sup> A técnica de correção geométrica denomina-se registro quando não existe nenhum sistema de referência associado à imagem que se pretende corrigir (tem-se somente um sistema 'linha x coluna'). Por outro lado, essa técnica costuma ser chamada de georreferenciamento quando existe, previamente, um sistema associado à imagem, ou seja, uma projeção cartográfica (ex.: projeção UTM – Universal Transversa de Mercator).



A utilização de composições coloridas é fundamentada pelo fato de que o olho humano é capaz de discriminar mais facilmente cores do que tons de cinza. Sendo assim, para cada banda, associa-se uma cor denominada primária (vermelho/*red* – R, verde/*green* – G ou azul/*blue* – B) e, a partir da combinação destas, podem ser produzidas as cores secundárias, tais como: magenta (vermelho + azul), ciano (verde + azul) e amarelo (vermelho + verde). Conforme a associação das cores RGB às bandas, os alvos serão representados por uma ou outra cor secundária, gerando diferentes composições coloridas (MOREIRA, 2001).

### 3.2 Classificação de imagens multiespectrais

A classificação é uma das técnicas mais freqüentes usadas para a extração de informações de dados de sensoriamento remoto (JENSEN, 1996) e implica no reconhecimento de padrões e feições homogêneas em uma imagem. A discriminação e o posterior reconhecimento desses padrões é possível devido aos diferentes alvos da superfície terrestre apresentarem um comportamento espectral específico (SCHOWENGERDT, 2007).

Existem duas abordagens que geralmente são utilizadas para realizar o processo de classificação. A primeira, tradicionalmente referenciada como análise visual, envolve uma interação direta entre o analista e os dados representados na imagem, e é bastante efetiva na avaliação dos aspectos globais de uma cena e na definição dos tipos de classes. Por outro lado, quando se trata da utilização de computadores para avaliar automaticamente a natureza multiespectral de uma imagem, são empregadas técnicas de análise digital (RICHARDS; JIA, 1999), as quais tendem a tornar o processo de mapeamento menos subjetivo e com maior potencial de repetição em situações subseqüentes (NOVO, 1992).

Muitas vezes, a análise visual de imagens é feita no próprio computador, onde são considerados os diferentes elementos de interpretação de imagens (tonalidade, padrão, forma, tamanho, textura, sombra, associação e localização) e selecionada a composição colorida que melhor permita a identificação das classes de interesse.

A classificação de imagens é o processo utilizado para produzir mapas temáticos (SCHOWENGERDT, 2007). Para atingir essa finalidade deve-se prever, inicialmente, a definição de um sistema de classificação que seja adequado ao estudo que se





pretende desenvolver. Esse sistema deve especificar claramente as classes de informação que constarão no mapeamento temático e os critérios usados para distingui-las. Assim, classificar envolve, necessariamente, a definição dos limites das classes, os quais devem ser claros, possivelmente quantitativos e baseados em critérios objetivos (DI GREGÓRIO, 2004).

As técnicas de classificação são normalmente baseadas em duas abordagens (RICHARDS; JIA, 1999). A primeira é denominada classificação supervisionada e implica na interação do analista e o sistema de análise com base em um conhecimento prévio da cena, o qual habilitará o analista a fornecer informações específicas e treinar o algoritmo de classificação (GONZALEZ; WOODS, 2000). Assim, um conjunto de dados de treinamento contendo exemplos de padrões de todas as classes temáticas existentes no sistema é usado pelo classificador para tomar decisões, bem como para calcular estatísticas descritivas (por exemplo, média e variância) para cada classe (ZHANG; FOODY, 2001).

A outra abordagem é chamada de classificação não-supervisionada, onde os elementos de uma imagem são associados a classes espectrais, sem que haja um conhecimento prévio da existência ou do nome dessas classes. A estratificação da cena é definida sem a interferência do analista na atribuição de cada elemento da imagem a uma determinada classe espectral. Normalmente, as classes espectrais são definidas com base no agrupamento de *pixels* que apresentam similaridade espectral através da aplicação de métodos de agregamento, utilizando medidas de similaridade (ex.: distância Euclidiana) (RICHARDS; JIA, 1999). Nesse caso, a vantagem consiste exatamente na não exigência de nenhum conhecimento *a priori* da área de estudo, confiando apenas na estrutura espectral interna do conjunto de dados.

Considerando o elemento de análise, os classificadores podem ser divididos em: por *pixel* e por regiões. Os classificadores por *pixel* utilizam apenas a informação espectral, isoladamente de cada *pixel*, para encontrar a classe mais provável para o *pixel*. Por outro lado, os classificadores por regiões agrupam *pixels* vizinhos com características similares e depois classificam esses agrupamentos (regiões) considerando os atributos espectrais da região e os parâmetros espaciais que podem ser derivados da distribuição espacial dos *pixels* que formam a região (VENTURIERI; SANTOS, 1998).

### 3.2.1 Classificação por redes neurais artificiais

As redes neurais artificiais (RNA's) foram primeiramente desenvolvidas com o objetivo de compreender o funcionamento do cérebro humano e, de alguma forma, procurar reproduzi-lo. Constituem estruturas formadas por um grande número de elementos de processamento, denominados neurônios artificiais (nós ou elementos de processamento), que tem como principal função distribuir padrões de ativação através de suas conexões (ou sinapses), de maneira similar ao mecanismo básico do cérebro humano, onde o processamento da informação se baseia na transferência de ativação de um grupo de neurônios para outro, através das sinapses.

Conforme Lippmann (1987), os elementos de processamento são conectados através de pesos e cada nó produz um somatório das várias entradas, ponderadas pelos pesos de suas respectivas conexões, passando o resultado através de uma função de decisão, cujo limiar interno e tipo de função é que caracterizam os nós. Para o autor, os modelos de RNA's são especificados através de três propriedades importantes: a arquitetura da rede; as características dos nós (tipo e limiar interno da função de decisão utilizada); e o algoritmo de treinamento ou aprendizagem.

A arquitetura da rede é a maneira como os neurônios são organizados, isto é, o número de camadas, a quantidade de elementos de processamento e como os neurônios são conectados, e está diretamente ligada ao desempenho da rede (TUBB, 1993). Dentre as arquiteturas mais usuais, merecem destaque os modelos baseados em estruturas de *perceptron*, os quais evoluíram para arquiteturas do tipo *perceptron* com múltiplas camadas (MLP), a partir do desenvolvimento de algoritmos de treinamento mais adequados (LIPPMANN, 1987). As redes do tipo MLP têm sido utilizadas com sucesso para a solução de vários problemas envolvendo altos graus de não-linearidade, ou seja, para lidar com dados muito similares (HAYKIN, 1999).

Gonzalez e Woods (2000) descrevem a arquitetura básica de uma rede neural multicamadas, na qual neurônios estruturalmente idênticos são arranjados de modo que a saída de cada neurônio em cada camada alimente a entrada de cada um dos neurônios da camada seguinte, conforme representado na Figura 4. O número de neurônios da camada de entrada (*input layer*) corresponde à dimensionalidade do vetor de atributos dos dados de entrada e, na camada de saída (*output layer*), a quantidade de neurônios está relacionada ao número de classes a serem mapeadas. O problema maior, que geralmente tem sido resolvido



por tentativa e erro ou pela experiência prévia no domínio de uma dada situação, está na definição do número de camadas intermediárias ou escondidas (*hidden layers*) e do número de neurônios que as compõem.

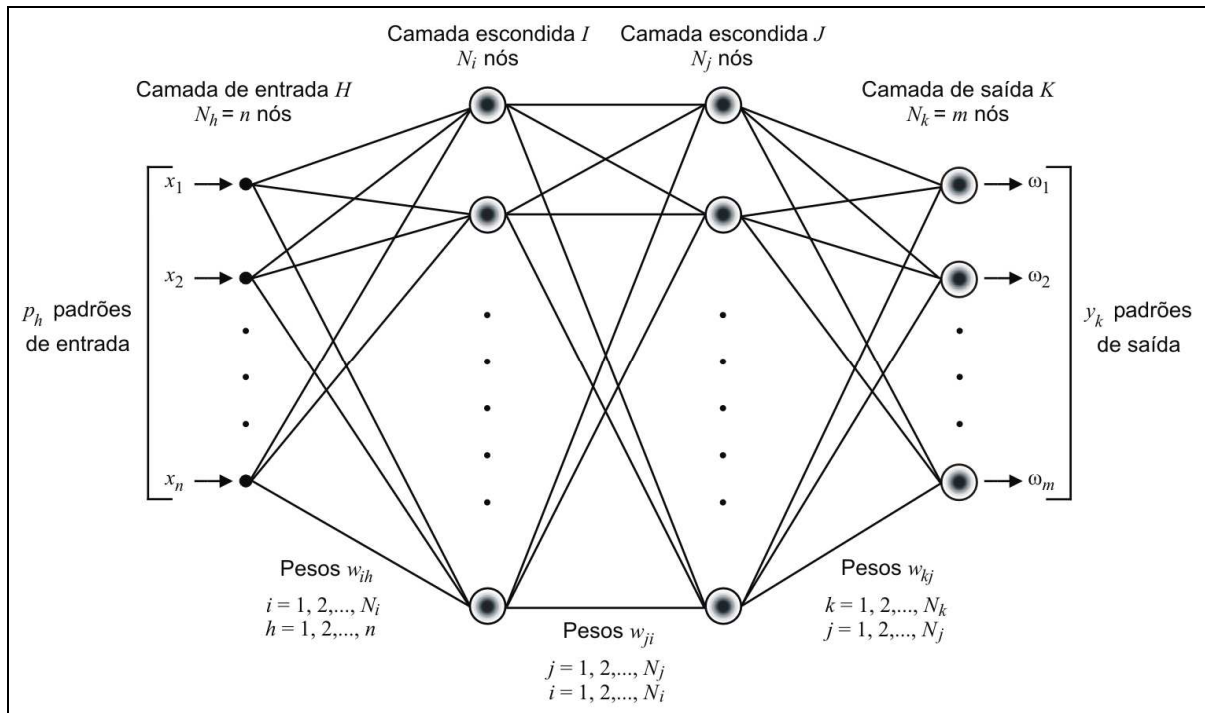


Figura 4: Diagrama esquemático de uma rede neural artificial com quatro camadas.  
Fonte: Adaptado de Gonzalez e Woods (2000) e Schowengerdt (2007).

A Figura 4 mostra o diagrama esquemático da arquitetura de uma rede neural artificial com quatro camadas: a camada de entrada  $H$ ; duas escondidas, designadas  $I$  e  $J$ ; e a camada de saída  $K$ . Os vetores  $x_1, x_2, \dots, x_n$  representam o conjunto de  $p_h$  padrões de entrada, para  $n = h$ ;  $w_{ih}$ ,  $w_{ji}$  e  $w_{kj}$  correspondem aos pesos que são ajustados durante o treinamento; e  $\omega_1, \omega_2$  e  $\omega_m$  se referem às  $m$  classes, isto é, aos  $y_k$  padrões de saída da rede, dado que  $m = k$ . A rede neural reconhece um vetor de padrões  $x_n$  como pertencente à classe  $\omega_m$  se a  $m$ -ésima saída da rede for “alta”, enquanto as demais forem “baixas” (GONZALEZ; WOODS, 1992).

Um neurônio artificial pode ser entendido como uma unidade de processamento matematicamente simples, a qual recebe uma ou mais entradas e as transforma em saída (TUBB, 1993), como pode ser observado na Figura 5, considerando um neurônio  $k$  da camada de saída. Esse neurônio está conectado aos neurônios da camada anterior  $J$  e cada conexão (sinapse) é caracterizada por um peso ( $w$ ), que representa a sua intensidade. A partir

dessas conexões, o neurônio  $k$  recebe um valor de entrada, denominado entrada do elemento de ativação ( $u_k$ ), que é calculado pela soma ponderada das saídas da camada anterior, conforme a Equação:

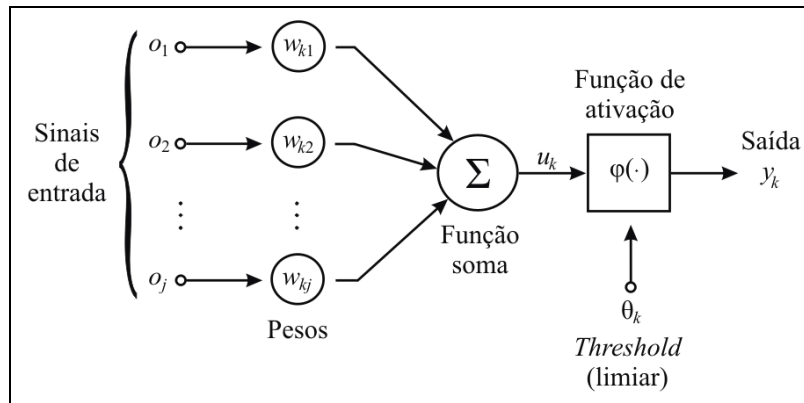


Figura 5: Esquema de um neurônio artificial.  
Fonte: Adaptado de Haykin (1999).

$$u_k = \sum_{j=1}^{N_j} w_{kj} o_j \quad (1)$$

para  $k = 1, 2, \dots, N_k$ , onde:  $N_k$  é o número do elemento da camada de saída;  $N_j$  é o número de nós da camada  $J$ ; e  $w_{kj}$  são os pesos que modificam as saídas  $o_j$ , antes de eles alimentarem os elementos da última camada. Por outro lado, as saídas da camada  $J$  serão definidas por:

$$o_j = \varphi(u_j) \quad (2)$$

para  $j = 1, 2, \dots, N_j$ , onde  $\varphi(\cdot)$  é a função de ativação (ou de decisão) (HAYKIN, 1999). Essa função define a saída de um neurônio em relação ao nível de atividade do mesmo, usualmente sendo utilizada a função sigmóide. Para o neurônio  $k$ , considerado na Figura 5, a função sigmóide pode ser obtida pela Equação:

$$\varphi(u_k) = \frac{1}{1 + \exp[-(u_k + \theta_k)/\theta_0]}; \quad (3)$$

onde:  $\theta_k$  é um limiar (ou *threshold*) acrescido ao somatório dos coeficientes; e  $\theta_0$  é o parâmetro que controla a forma da função de ativação sigmoidal definida para cada neurônio.



O resultado da Equação 3 produz o valor de ativação do  $k$ -ésimo elemento da camada de saída. Se o valor de  $u_k$  for menor que  $\theta_k$ , a saída do neurônio fica inibida, caso contrário, o neurônio fica ativo. Essa saída pode ser definida por:

$$y_k = \varphi(u_k, \theta_k). \quad (4)$$

Os algoritmos de treinamento são um conjunto de regras bem definidas para a solução de um problema de aprendizado (TATIBANA; KAETSU, 2008). Dentre esses algoritmos, o mais conhecido e utilizado para aprendizagem supervisionada é o retro-propagação do erro (*error backpropagation*), ou regra delta generalizada. Esse algoritmo permite o ajuste dos pesos em cada uma das camadas da rede e é projetado para minimizar a soma do quadrado do erro (ou erro médio quadrático) entre a saída calculada e a saída desejada. O componente essencial do algoritmo é o método iterativo que propaga regressivamente o erro requerido para adaptar os pesos, a partir dos neurônios da camada de saída para os nós das camadas precedentes (LIPPMANN, 1987).

Conforme Galo (2000), o processo de treinamento pelo algoritmo *backpropagation* começa com a definição de um conjunto arbitrário de pesos para as conexões da rede. A partir disso, um vetor de treinamento, com a respectiva saída desejada, é apresentado à rede e propagado através de suas camadas para computar uma saída para cada elemento de processamento. As saídas dos nós da última camada são, então, comparadas com as saídas desejadas e, em seguida, são calculados os erros. A etapa seguinte envolve um retrocesso, isto é, uma passagem de volta através da rede a partir da última camada, onde o erro é repassado para cada elemento de processamento e os pesos correspondentes são convenientemente alterados. Por conta dessa retro-propagação do erro, esse tipo de rede neural artificial é conhecido como rede multicamadas “*feedforward*”.

Quando um padrão é apresentado à rede pela primeira vez, uma saída aleatória é produzida. A diferença entre essa saída calculada e a desejada constitui o erro. A intenção do treinamento é buscar, a cada iteração, minimizar o valor desse erro. A regra *backpropagation* faz com que os pesos da camada de saída sejam os primeiros a serem ajustados e, posteriormente, os pesos das demais camadas, de trás para frente (RAIA JR., 2000).



O erro quadrático total obtido para um determinado padrão, considerando o valor da saída desejada,  $d_k$  (para o neurônio  $k$ ), e o valor da saída calculada,  $y_k$ , durante a  $n$ -ésima iteração, é dado por:

$$E(n) = \frac{1}{2} \sum_{k \in C} (d_k(n) - y_k(n))^2; \quad (5)$$

onde: o conjunto  $C$  inclui todos os neurônios da camada de saída da rede (HAYKIN, 1999).

A atualização dos pesos da rede é feita através da aplicação de um termo de variação ( $\Delta$ ). Assim, para um dado peso  $w_{kj}$ , a sua atualização computada na iteração  $(n+1)$  é obtida por:

$$w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj}. \quad (6)$$

A partir da Equação 6, existem duas possibilidades distintas: (i) ajuste dos pesos da camada de saída da rede; e (ii) ajuste dos pesos das camadas intermediárias. Para o primeiro caso, considerando um neurônio  $k$  pertencente à camada de saída e um neurônio  $j$  da camada anterior, conforme a Figura 4, o peso  $w_{kj}$  será atualizado computando:

$$\Delta w_{kj} = \eta \delta_k y_j \quad (7)$$

onde:

$$\delta_k = y_k (d_k - y_k) (1 - y_k). \quad (8)$$

sendo que:  $\delta_k$  é a diferença (erro) entre a camada de saída calculada ( $y_k$ ) e a saída desejada ( $d_k$ ) do neurônio  $k$ ; e  $\eta$  é o parâmetro denominado taxa de aprendizado (*learning rate*) e seu valor é responsável por determinar quão suave se dará a atualização dos pesos da rede, ou seja, quanto maior o valor de  $\eta$ , mais brusca será a alteração dos pesos (HAYKIN, 1999).

Por outro lado, para o ajuste dos pesos de uma camada escondida, considerando, por exemplo, o neurônio  $j$  pertencente à camada  $J$ , seu peso  $w_{ji}$  será atualizado por:



$$\Delta w_{ji} = \eta \delta_j y_i \quad (9)$$

onde:

$$\delta_i = y_i (1 - y_i) \sum w_{kj} \delta_j . \quad (10)$$

Outro parâmetro que pode ser incluído na atualização dos pesos é o fator de impulso (*momentum factor*), que permite aumentar a velocidade do aprendizado e, conseqüentemente, a velocidade de convergência da rede.

Após o treinamento da rede e, portanto, dispondo dos pesos das conexões ajustados, esta é aplicada ao conjunto de dados e os padrões são classificados como pertencentes a uma determinada classe, quando a saída para essa classe for alta e baixa para as demais classes. Em outras palavras, o critério de decisão geral estabelece que cada padrão deve ser atribuído à classe cujo elemento de processamento da camada de saída produzir o maior resultado numérico. Para algumas implementações de rede neural artificial, além dessa saída ser maior para uma das classes, ela deve ter um valor superior a um limite de tolerância, para que o padrão possa ser atribuído àquela classe (GALO, 2000).

### 3.2.2 Classificação baseada em abordagem *fuzzy*

A matemática e a lógica tradicional (ou *booleana*) já conseguiram mapear satisfatoriamente um incontável número de processos de cálculo e decisão. Porém, muitas experiências humanas necessitam de um enfoque mais abrangente do que a simples associação de falso ou verdadeiro, sim ou não, certo ou errado (LIMA JR., 2002).

Nesse contexto, a lógica *fuzzy* (ou lógica nebulosa) surge como uma alternativa para representar modelos de raciocínio impreciso, necessários à tomada de decisões racionais em ambientes de incertezas e imprecisões. Essa teoria foi proposta por Lotfi Zadeh, em 1965, que a definiu como a parte da lógica matemática dedicada ao raciocínio incerto ou aproximado, utilizada para caracterizar classes que, por diversas razões, não possuem limites rígidos entre si (ZADEH, 1965).



Na lógica *booleana*, um conjunto  $A$  pertencente a um domínio  $X$  pode ser representado por uma função característica  $A(x)$ , cujos valores dessa função podem ser igual a 1, se  $x \in X$ , ou igual a 0, se  $x \notin X$ . Essa estrutura restritiva é ideal para conjuntos com limites bem definidos pois, para qualquer objeto que pertença ao domínio  $X$ , pode-se determinar com exatidão se o mesmo pertence ou não ao conjunto  $A$  (ZADEH, 1965).

Por outro lado, um conjunto *fuzzy* é caracterizado por uma função de pertinência (*membership function*) que mapeia os elementos de um espaço ou domínio  $X$  para um número real em  $[0,1]$  ou, formalmente,  $A: X \rightarrow [0,1]$ . Dessa forma, um conjunto *fuzzy* apresenta-se como um conjunto de pares ordenados, em que o primeiro elemento é  $x \in X$ , e o segundo,  $f_A(x)$ , é o grau de pertinência (ou a função de pertinência) de  $x$  em  $A$ , que mapeia  $x$  no intervalo  $[0,1]$ , ou seja,  $A = \{(x, f_A(x)) / x \in X\}$  (ZADEH, 1965).

Em classificação de imagens multiespectrais, normalmente, a informação de interesse é extraída por meio de técnicas de classificação convencionais, as quais são baseadas na lógica *booleana* e o *pixel* é atribuído a uma única classe de cobertura da terra, desconsiderando a existência de qualquer proporção de contribuição de outras classes para esse *pixel*. Essas técnicas de representação têm dificuldades em lidar com fenômenos que não podem ser descritos por uma pertinência total a um único conjunto (WANG; BRENT HALL; SUBARYONO, 1990), como misturas entre tipos de cobertura, que ocorrem frequentemente, implicando em perda substancial de informação espectral útil (MASELLI; RODOLFI; CONESE, 1996).

Contudo, muitos fenômenos geográficos não existem em classes discretas, mas estão ao longo de um contínuo. Por exemplo, tipos adjacentes de cobertura da terra raramente são separados por limites nitidamente definidos, mas sim por zonas de transição, nas quais nenhum tipo de cobertura pode claramente dominar (ZHANG; STUART, 2001). Enquanto nessas zonas de transição (isto é, nesse contínuo) entre classes os *pixels* serão compostos por proporções variáveis de diferentes classes, caracterizando *pixels* mistos, além desse contínuo, os *pixels* poderão ser “puros” e incluir apenas espécies associadas a uma única classe (FOODY, 1992).

A exata proporção de *pixels* mistos em uma imagem irá variar com uma gama de fatores, principalmente com o mosaico de cobertura da terra ao redor e com a resolução espacial do sensor. Essa proporção aumenta, geralmente, com a diminuição da resolução espacial do sensor. Assim, para dados de baixa e média resolução espacial usados em mapeamentos nas escalas regional e global, onde talvez o sensoriamento remoto orbital é a





principal fonte de dados em mapeamentos temáticos, *pixels* mistos podem dominar as imagens (FOODY et al., 1997).

Dessa forma, quando existe uma única classe de cobertura da terra, o *pixel* registra as características espectrais dessa classe. No entanto, quando a região contém uma mistura de classes de cobertura, o valor do *pixel* é uma função da reflectância de uma mistura das classes componentes (GOPAL; WOODCOCK, 1994). Assim, *pixels* mistos (ou heterogêneos) têm suas características espectrais que diferem daquelas de um *pixel* homogêneo (WANG, 1990).

Para agrupar *pixels* em classes, o espaço multiespectral é particionado em regiões, cada qual correspondendo a uma das classes de cobertura definidas. As classes representadas como conjuntos clássicos dão origem a uma partição rígida do espaço multiespectral (Figura 6) (WANG, 1990), e, assim, considera-se que as mudanças entre uma classe de cobertura e outra são estabelecidas por limites rígidos e bem definidos (CANTERS, 1997).

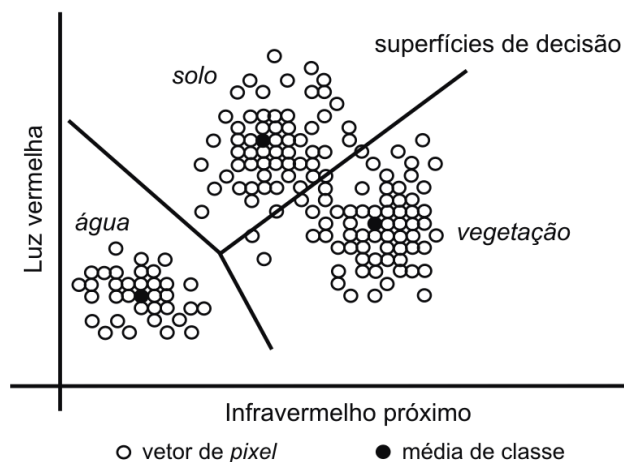


Figura 6: Partição rígida do espaço multiespectral.  
Fonte: Adaptado de Wang (1990).

Por outro lado, quando as classes de cobertura são representadas como conjuntos *fuzzy*, o espaço multiespectral não é particionado por superfícies rígidas, gerando uma classificação *fuzzy* (ou *soft classification*). Assim, graus de pertinência são atribuídos aos *pixels* para indicar a extensão com que estes pertencem a cada classe. Tal partição é chamada de partição *fuzzy* do espaço multiespectral. A Figura 7 ilustra os graus de pertinência de um *pixel* em uma partição *fuzzy* (WANG, 1990).

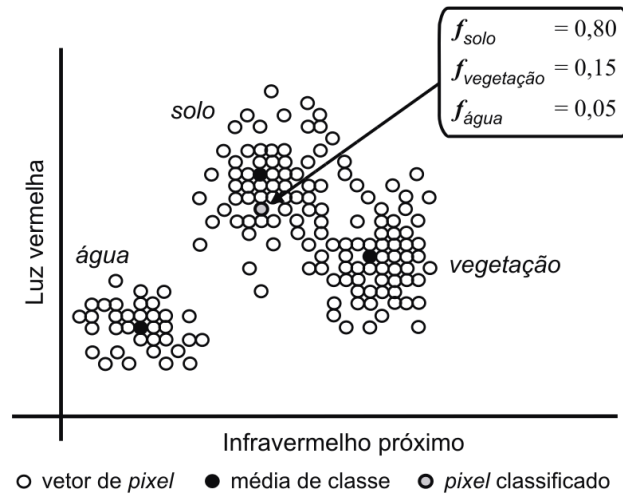


Figura 7: Pertinência de um pixel em uma partição fuzzy do espaço multispectral.  
Fonte: Adaptado de Wang (1990).

A partição *fuzzy* do espaço multispectral pode ser expressa na forma de uma matriz de partição *fuzzy* (WANG, 1990):

$$\begin{bmatrix} f_{\omega_1(\bar{x}_1)} & f_{\omega_1(\bar{x}_2)} & \cdots & f_{\omega_1(\bar{x}_n)} \\ f_{\omega_2(\bar{x}_1)} & f_{\omega_2(\bar{x}_2)} & \cdots & f_{\omega_2(\bar{x}_n)} \\ \vdots & \vdots & \ddots & \vdots \\ f_{\omega_m(\bar{x}_1)} & f_{\omega_m(\bar{x}_2)} & \cdots & f_{\omega_m(\bar{x}_n)} \end{bmatrix}; \quad (11)$$

onde:  $\omega_1, \dots, \omega_m$  representam as  $m$  classes espectrais;  $\bar{x}_1, \dots, \bar{x}_n$  são os vetores de atributos dos *pixels*;  $n$  é o número de *pixels*; e  $f_{\omega_1}, \dots, f_{\omega_m}$  são as funções de pertinência para as classes.

### – Classificação relativa bayesiana

Existem várias maneiras de derivar uma classificação *fuzzy*, dentre as quais destaca-se a classificação relativa bayesiana. Nessa técnica são consideradas a média e a matriz de variância e covariância ponderadas, cujos pesos são graus de pertinência *fuzzy*

estimados a partir de dados de treinamento para as classes (EASTMAN; LANEY, 2002). Assim, a média *fuzzy* ( $\vec{m}_c^*$ ) é calculada como:

$$\vec{m}_c^* = \frac{\sum_{i=1}^n f_c(\vec{x}_i) \cdot \vec{x}_i}{\sum_{i=1}^n f_c(\vec{x}_i)}; \quad (12)$$

onde:  $n$  é o número total de *pixels* de treinamento;  $\vec{x}_i$  é o vetor de atributos do *pixel* da amostra; e  $f_c$  é a função de pertinência da classe  $c$  (a proporção de classe de cobertura  $c$  na amostra de treinamento).

De modo similar, segundo Wang (1990), a matriz de covariância *fuzzy* ( $\Sigma_c^*$ ) é calculada como:

$$\Sigma_c^* = \frac{\sum_{i=1}^n f_c(\vec{x}_i) \cdot (\vec{x}_i - \vec{m}_c^*) \cdot (\vec{x}_i - \vec{m}_c^*)^T}{\sum_{i=1}^n f_c(\vec{x}_i)}. \quad (13)$$

Uma vez que as estatísticas de treinamento são desenvolvidas, o estágio de classificação pode ser realizado. A pertinência de uma classe é definida com base na lógica da classificação de Máxima Verossimilhança, mas usando a média e a matriz de covariância *fuzzy* substituindo média e matriz de covariância convencionais, isto é:

$$f_c(\vec{x}) = \frac{P^*(\vec{x} | \omega_c)}{\sum_{i=1}^m P^*(\vec{x} | \omega_i)}; \quad (14)$$

onde:  $P^*(\vec{x} | \omega_i)$  é a função densidade de probabilidade normal para a classe  $i$ , apresentada na Equação 15:

$$P^*(\vec{x} | \omega_i) = \frac{1}{(2\pi)^{N/2} |\Sigma_i^*|^{1/2}} e^{\left[ -0,5(\vec{x} - \vec{m}_i^*)^T \Sigma_i^{*-1} (\vec{x} - \vec{m}_i^*) \right]}; \quad (15)$$



$N$  é o número de bandas espectrais utilizadas; e  $m$  é o número de classes ( $1 \leq i \leq m$ ) (WANG, 1990).

Os graus de pertinência a serem determinados para cada *pixel* dependem da posição desse *pixel*, isto é, do seu vetor de atributos  $\vec{x}$  no espaço multiespectral. A função de pertinência  $f_c(\vec{x})$  aumenta exponencialmente com a diminuição de  $(\vec{x} - \vec{m}_c^*)^T \Sigma_c^{*-1} (\vec{x} - \vec{m}_c^*)$ , ou seja, a distância de Mahalanobis entre  $\vec{x}$  e a classe  $c$ . O valor  $\sum_{i=1}^m P^*(\vec{x} | \omega_i)$  é um fator normalizante (JENSEN, 1996).

### 3.3 Confiabilidade do mapeamento

Tomadas de decisão que envolvem os recursos naturais existentes no planeta requerem o uso de mapas, os quais ajudam a medir a extensão e distribuição dos recursos, analisar interações, identificar locais apropriados para ações específicas (por exemplo, intervenção ou preservação de um local) e planos para eventos futuros. Contudo, decisões eficazes requerem mapas de acurácia<sup>4</sup> conhecida (CONGALTON; GREEN, 1999).

A acurácia de mapas pode ser medida por dois tipos de critérios: acurácia posicional e acurácia temática (ou acurácia da classificação). A acurácia posicional refere-se à quão exata é a localização das feições existentes no mapa em relação à sua verdadeira posição na superfície terrestre. Por sua vez, a acurácia temática está relacionada à acurácia das classes temáticas descritas no mapa em relação às correspondentes na realidade (CONGALTON; GREEN, 1999).

Dessa forma, para verificar a confiabilidade (ou qualidade) de um mapeamento de uso e cobertura da terra, convencionalmente é feita a análise da acurácia temática baseada no cálculo de coeficientes estatísticos. Esse procedimento permite que um grau de confiança seja anexado aos resultados da classificação (RICHARDS; JIA, 1999). Assim, verifica-se até que ponto a classe de informação definida é adequada e quão corretamente está representada no mapa temático. Outra alternativa é a análise da incerteza associada ao processo de classificação. Essas duas abordagens para estimativa da qualidade da classificação são descritas a seguir.

<sup>4</sup> Os termos “acurácia” e “exatidão” são considerados sinônimos, sendo utilizados para expressar quão próxima uma observação (ou medida) está do seu valor real.



### 3.3.1 Estimativas de acurácia baseada em coeficientes estatísticos

A avaliação da acurácia é o processo usado para estimar a acurácia do mapeamento confrontando o resultado da classificação com dados de referência denominados “verdades terrestres”. O objetivo desse processo é a produção de uma matriz de erros, a partir da qual coeficientes estatísticos podem ser derivados e indicam a acurácia de classes individuais e de todo o mapa. Para a geração da matriz de erros devem ser considerados quatro fatores: (i) os dados de referência; (ii) o tipo de unidade de amostra (ou elemento amostral); (iii) a quantidade de amostras (ou número de elementos amostrais); e (iv) o esquema de amostragem (CAETANO; MATA; FREIRE, 2006).

Os dados de referência devem ter um grau de acurácia mais alto que os dados usados para a geração do mapeamento e podem incluir: fotografias aéreas; imagens orbitais de melhor resolução espacial que aquela usada na produção do mapa; e levantamento de campo, ou seja, dados coletados *in situ* (CAETANO; MATA; FREIRE, 2006). Congalton e Green (1999) criticam o uso de mapas temáticos pré-existentes como dados de referência, visto que, raramente, esses mapas foram elaborados a partir do mesmo projeto de classificação.

Unidades de amostra são fragmentos do mapeamento temático que irão compor o conjunto de elementos amostrais. Dentre as opções existentes, tais como único *pixel*, cluster (conjunto) de *pixels* (3x3, 5x5 etc.), polígono e cluster de polígonos, Congalton e Green (1999) afirmam que um cluster de *pixels* é convencionalmente preferível, devido a sua identificação mais fácil nos dados de referência e ao fato de permitir delinear melhor a paisagem em relação ao uso do *pixel* individual.

Um número adequado de elementos amostrais por classe deve ser coletado para que a análise realizada seja estatisticamente válida. Para tanto, duas estratégias podem ser utilizadas para validar o número de amostras: a distribuição binomial e a multinomial (CAETANO; MATA; FREIRE, 2006). O modelo binomial é apenas apropriado para computar o número de amostras necessário para uma única classe, visto que este simplesmente faz a distinção entre classificação correta e incorreta e não considera o conjunto de classes analisadas. Por outro lado, na distribuição multinomial o processo de validação não é uma questão apenas de certo e errado, mas o erro deve ser classificado em relação ao total de possibilidades (ou conjunto de classes), de modo que o uso dessa distribuição implica no conhecimento *a priori* do número de classes e suas proporções no mapa, conforme a Equação:



$$n_i = \frac{\chi_{(1,1-(\alpha/m))}^2 p_i (1 - p_i)}{d_i^2}; \quad (16)$$

onde:  $n_i$  é o tamanho da amostra para a classe  $i$ , com  $i = 1, 2, \dots, m$ ;  $\chi_{(1,1-(\alpha/m))}^2$  é o valor para o nível de confiança desejado  $(\alpha/m)$  com 1 grau de liberdade e  $(1 - \alpha/m)$ , considerando a distribuição qui-quadrado;  $p_i$  é a proporção representativa da classe  $i$  no mapeamento; e  $d_i$  é o erro permissível (ou precisão desejada). O número mínimo de amostras ( $n$ ) a ser considerado para cada classe será:

$$n = \max_i \left\{ \frac{n_i}{m} \right\}. \quad (17)$$

O tamanho do conjunto amostral também pode ser ajustado com base na importância relativa das classes dentro dos objetivos do projeto de classificação. Algumas vezes é melhor concentrar a amostragem nas classes de interesse, aumentando o número de elementos amostrais nessas classes e reduzindo aqueles coletados nas demais classes de menor relevância (CONGALTON; GREEN, 1999).

Além da unidade de amostra e do tamanho do conjunto amostral, a distribuição das amostras tem um importante papel na análise da acurácia. Para assegurar uma conclusão válida sobre a acurácia do mapa, existe a necessidade de que essa distribuição seja feita sem tendência. A não consideração desse critério pode resultar em uma matriz de erros que superestima (ou subestima) a verdadeira acurácia.

Existem cinco esquemas de amostragem usuais, os quais são: amostragem aleatória simples; amostragem sistemática; amostragem aleatória estratificada; amostragem por cluster (agregamento); e amostragem sistemática estratificada não-alinhada (CONGALTON; GREEN, 1999). Em uma amostragem aleatória simples, cada unidade na área de estudo tem uma chance igual de ser selecionada, um gerador de números aleatórios é usado para escolher coordenadas  $(x, y)$  das amostras. O benefício da aleatoriedade é que cada unidade na área de estudo tem uma chance igual e independente de ser selecionada, assegurando que não haja tendência. A amostragem aleatória estratificada é similar à amostragem aleatória simples, mas algum conhecimento *a priori* da área de estudo é usado para dividir a área em grupos ou estratos (isto é, classes de cobertura, em mapeamentos temáticos). A maior vantagem, nesse caso, é que todos os estratos, independente do tamanho,



serão amostrados.

Na amostragem sistemática as unidades de amostra são selecionadas com um intervalo igual sobre a área de estudo. Na maioria dos casos, a primeira amostra é selecionada aleatoriamente e cada amostra sucessiva é adicionada depois com um intervalo específico. A amostragem sistemática estratificada não-alinhada tenta combinar as vantagens da aleatoriedade e estratificação com a facilidade de uma amostragem sistemática. Além disso, o esquema de amostragem por cluster tem sido também especialmente para coletar informação de muitas amostras rapidamente, mas esse método deve ser usado com cautela, evitando formar clusters maiores que 10 *pixels*.

Congalton e Green (1999) dizem que a amostragem aleatória simples não garante uma distribuição espacial adequada dos elementos amostrais dentro da área de interesse, pois esta tende a distribuir poucos elementos amostrais para classes pequenas, contudo, que podem ser importantes para o projeto de classificação. Os citados autores também destacam que esquemas de amostragem sistemática, por cluster e sistemática estratificada não-alinhada devem ser utilizados com precaução, visto que tendem a superestimar os elementos amostrais. Assim, muitos analistas preferem a amostragem aleatória estratificada, que combina baixo potencial de tendência (esquema aleatório) com a propriedade de maior cobertura geográfica (estratificação), assegurando que um número mínimo de amostras seja selecionado para cada estrato.

Após a especificação dos parâmetros necessários à geração da matriz de erros, a mesma pode ser definida. Conforme Congalton e Green (1999), constrói-se uma matriz de erros (Tabela 3) com  $n$  elementos amostrais distribuídos em  $m^2$  células, onde cada elemento amostral é atribuído a uma das  $m$  classes na classificação (usualmente as linhas) e, independentemente, para uma mesma classe  $m$  identificada no conjunto de dados de referência (usualmente as colunas). Logo,  $x_{ij}$  denota o número de amostras associadas à classe mapeada  $i$  ( $i = 1, 2, \dots, m$ ), resultantes da classificação, e à categoria  $j$  ( $j = 1, 2, \dots, m$ ), extraídas do conjunto de dados de referência. Ainda,  $\sum x_{i+}$  e  $\sum x_{+j}$  expressam o somatório dos totais marginais  $x_{i+}$  e  $x_{+j}$  das linhas  $i$  e colunas  $j$ , respectivamente.



Tabela 3: Estrutura da matriz de erros (ou de confusão).

|               |               | Verdade Terrestre |          |     |          | $\sum x_{i+}$ |
|---------------|---------------|-------------------|----------|-----|----------|---------------|
|               |               | 1                 | 2        | ... | $m$      |               |
| Classificação | 1             | $x_{11}$          | $x_{12}$ | ... | $x_{1m}$ | $x_{1+}$      |
|               | 2             | $x_{21}$          | $x_{22}$ | ... | $x_{2m}$ | $x_{2+}$      |
|               | ...           | ...               | ...      | ... | ...      | ...           |
|               | $M$           | $x_{m1}$          | $x_{m2}$ | ... | $x_{mm}$ | $x_{m+}$      |
|               | $\sum x_{+j}$ | $x_{+1}$          | $x_{+2}$ | ... | $x_{+m}$ | $n$           |

Fonte: Adaptado de Congalton e Green (1999).

A estimativa da acurácia temática obtida a partir da matriz de erros é computada através da exatidão global ( $P_o$ ), que é a razão entre a soma de todos os elementos amostrais classificados corretamente pelo número total de elementos, conforme a Equação:

$$P_o = \frac{\sum_{i=1}^m x_{ii}}{n}; \quad (18)$$

onde:  $x_{ii}$  são os elementos da diagonal principal (corretamente classificados);  $m$  é o número de classes presentes na matriz; e  $n$  é o número total de elementos amostrais. Contudo, o resultado desse índice tende a superestimar o resultado da classificação, uma vez que este considera apenas a proporção de concordância plena, ou seja, as observações classificadas de maneira correta.

Outra estimativa que pode ser computada é o índice de concordância Kappa (também denominado KHAT ou KIA) entre a “verdade terrestre” e o mapeamento temático. Conforme Rosenfield e Fitzpatrick-Lins (1986), essa estatística pode ser obtida por:

$$\hat{\kappa} = \frac{P_o - P_c}{1 - P_c}; \quad (19)$$

onde:  $P_o$  é a proporção de plena concordância (ou exatidão global); e  $P_c$  é a proporção de concordância por casualidade, que é calculada por:

$$P_c = \frac{\sum_{i=1}^m (x_{i+} * x_{+j})}{n^2}; \quad (20)$$



dado que:  $m$  é o número de classes analisadas;  $x_{i+}$  e  $x_{+j}$  são os totais marginais da linha  $i$  e coluna  $j$ , respectivamente; e  $n$  é o número total de observações. Ao contrário da exatidão global, o índice de concordância *Kappa* incorpora também os elementos fora da diagonal principal e, por isso, tende a representar um valor mais confiável e inferior ao primeiro.

O resultado da estatística *Kappa* normalmente é comparado aos valores contidos na Tabela 4, proposta por Landis e Koch<sup>5</sup> (1977 apud MOREIRA, 2001), a fim de indicar a qualidade do mapa temático. Embora essa tabela tenha sido desenvolvida para analisar resultados de diagnósticos clínicos, a mesma tem sido referência para classificar mapas resultantes da utilização de imagens de sensoriamento remoto, dentro de certas restrições.

Tabela 4: Qualidade do mapa temático associada aos valores da estatística *Kappa*.

| Valor de <i>Kappa</i> | Qualidade do mapa |
|-----------------------|-------------------|
| < 0,00                | Péssima           |
| 0,00 – 0,20           | Ruim              |
| 0,20 – 0,40           | Razoável          |
| 0,40 – 0,60           | Boa               |
| 0,60 – 0,80           | Muito boa         |
| 0,80 – 1,00           | Excelente         |

Fonte: LANDIS e KOCH (1977 apud MOREIRA, 2001).

Além dos coeficientes estatísticos já mencionados, Ma e Redmond (1995) salientam a importância de utilizar um terceiro coeficiente para a análise da exatidão temática, o qual denomina-se índice de concordância *Tau* e pode ser obtido pela Equação:

$$\tau = \frac{P_o - P_r}{1 - P_r}; \quad (21)$$

onde:  $P_o$  é a exatidão global; e  $P_r$  é a proporção de concordância por casualidade, expressa por  $1/m$ , onde  $m$  é o número de classes. Dessa forma, a concordância por casualidade pode ser obtida, nessa estatística, antes mesmo de elaborar a matriz de erros, e consiste em uma medida direta da atribuição casual dos *pixels* às categorias. Por outro lado, a concordância casual ( $P_c$ ) calculada para *Kappa* pode resultar do julgamento do analista adicionado à casualidade, de tal forma que esse coeficiente superestima  $P_c$  e, conseqüentemente, subestima

<sup>5</sup> LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. *Biometrics*, v. 33, n. 1, p. 159-174, 1977.



a qualidade da classificação.

Os coeficientes de exatidão global, *Kappa* e *Tau*, consistem em índices de concordância total, ou seja, índices computados para toda a matriz. Contudo, outra alternativa para a análise da acurácia temática é por meio dos coeficientes de concordância para classes individuais. Nesse sentido, inicialmente pode-se destacar a análise dos erros de comissão (ou erros de inclusão) e dos erros de omissão (ou erros de exclusão) presentes na classificação (CONGALTON; GREEN, 1999). Um erro de comissão ocorre ao incluir um *pixel* na classe a qual ele não pertence, e o de omissão quando um *pixel* é excluído da classe a que pertence. Esses valores são obtidos na matriz de erros pelo cálculo da exatidão do usuário e do produtor, respectivamente.

A exatidão do usuário (*EU*) é expressa pela razão do número de elementos distribuídos corretamente em uma classe pelo número total de elementos classificados na mesma. Essa medida reflete os erros de inclusão da classificação e indica a probabilidade de um elemento amostral agrupado em uma determinada classe realmente pertencer à mesma (LILLESAND; KIEFER; CHIPMAN, 2004). É calculada segundo a Equação:

$$EU = \frac{x_{ii}}{x_{i+}}; \quad (22)$$

onde:  $x_{ii}$  é o número de elementos classificados corretamente; e  $x_{i+}$  é o total de elementos classificados em uma dada classe  $i$ .

A exatidão do produtor (*EP*) é a razão entre o número de elementos classificados corretamente em uma determinada classe pelo número de elementos de referência amostrados para a mesma classe (LILLESAND; KIEFER; CHIPMAN, 2004). Essa medida reflete os erros de exclusão da classificação, sendo expressa por:

$$EP = \frac{x_{ii}}{x_{+j}}; \quad (23)$$

onde:  $x_{ii}$  é o número de elementos classificados corretamente; e  $x_{+j}$  é o total de elementos de referência amostrados para uma dada classe  $j$ .

Além disso, o índice de concordância *Kappa* também pode ser computado para cada classe individualmente, ou seja, para a  $i$ -ésima classe, conforme Bishop, Feinberg e

Holland<sup>6</sup> (1975 apud ROSENFELD; FITZPATRICK-LINS, 1986). Para tanto, deve-se considerar a Equação:

$$\hat{\kappa}_i = \frac{(n * x_{ii}) - (x_{i+} * x_{+j})}{(n * x_{i+}) - (x_{i+} * x_{+j})}; \quad (24)$$

onde:  $n$  é o número total de elementos da matriz;  $x_{ii}$  é o número de elementos classificados corretamente para a  $i$ -ésima classe;  $x_{i+}$  e  $x_{+j}$  são os totais marginais da linha  $i$  e coluna  $j$ .

### 3.3.2 Análise da incerteza

Os coeficientes estatísticos (exatidão global, *Kappa* e *Tau*), normalmente utilizados para indicar o grau de exatidão de um mapeamento, constituem índices globais, ou seja, que consideram todo o mapa no processo de análise. A qualidade geral fornecida por esses índices é freqüentemente um padrão satisfatório, porém, isso não significa que a qualidade é uniformemente mantida ao longo de todo o mapeamento. Em algumas áreas, variações significantes nessa qualidade podem existir e esses locais podem ser de interesse especial para o usuário. Então, uma representação espacial dos pontos de maior incerteza na classificação pode informar, tanto ao analista quanto ao usuário, as variações locais na qualidade do mapa. Dessa forma, tão importante quanto conhecer a acurácia do mapeamento é avaliar as incertezas espacialmente distribuídas no mapa.

A incerteza é gerada pela imperfeição da informação na qual se baseia a tomada de decisões, sendo que essa imperfeição pode estar relacionada com várias características diferentes da informação, tais como: imprecisão, conflito, ignorância parcial ou total etc. A qualidade da decisão tomada a partir da informação fornecida irá depender, primeiramente, da própria qualidade da informação conhecida, que pode variar de perfeita a imperfeita, seja pela total ausência de informações ou por informações completamente conflitantes (BITTENCOURT, 2002). Em segundo lugar, a qualidade da decisão dependerá do modelo de representação escolhido e da sua adequação para tratar a informação disponível

<sup>6</sup> BISHOP, Y. M. M.; FEINBERG, S. E.; HOLLAND, P. W. **Discrete multivariate analysis: theory and practice**. Cambridge: MIT Press, 1975.



sendo que, para cada tipo de informação, existe um modelo formal conhecido de tratamento (SANTOS et al., 2003).

A incerteza que é introduzida durante a classificação de dados de sensoriamento remoto pode ser caracterizada pelos vetores de probabilidade que são produzidos como um subproduto da classificação, disponibilizados pela maioria dos procedimentos de classificação probabilísticos (GOODCHILD; SHI; FISHER, 2002). Por exemplo, na classificação pela probabilidade máxima *a posteriori*, para cada *pixel* da imagem multiespectral é calculado um vetor de probabilidades, o qual especifica a chance de uma dada classe se constituir na classe verdadeira. Se a observação sobre um *pixel* é entendida como um vetor de atributos  $\vec{x}_i$  que pode estar associado a uma das classes  $\omega_c$ , onde  $c = 1, \dots, m$ , então o vetor calculado para esse *pixel* especifica a probabilidade *a posteriori* ( $P(\omega_c | \vec{x}_i)$ ) que o dado *pixel* tem de pertencer à classe considerada (SABO, 2006).

Os vetores de probabilidade produzidos na classificação refletem as diferenças da incerteza para a classificação resultante e podem ser considerados indicativos de classificações duvidosas, *pixels* mistos, classes heterogêneas ou de limites ambíguos entre classes (GOODCHILD; SHI; FISHER, 2002). A partir desses vetores de probabilidade, várias medidas de incerteza podem ser estimadas. Um exemplo dessas medidas é a probabilidade máxima indicada no vetor de probabilidade, cujo valor expressa o grau de pertinência para a classe designada e a possível confusão com demais. Uma probabilidade máxima alta (ex.: 0,95) deixa poucas dúvidas a respeito da classificação do *pixel*. Por outro lado, uma probabilidade máxima baixa (ex.: 0,50) pode indicar atribuição duvidosa a uma determinada classe. A diferença entre a probabilidade máxima e a segunda maior probabilidade para um vetor de atributos pode, então, servir para esclarecer situações de dúvida, ao mesmo tempo em que fornece a informação sobre a certeza da classe mais provável (VAN DER WEL; VAN DER GAAG; GORTE, 1998).

Quando se trata de atributos temáticos, Felgueiras (1999) afirma que a incerteza pode ser definida pela moda da distribuição. Ou seja, a incerteza em  $\vec{x}_i$ ,  $Inc(\vec{x}_i)$ , pode ser determinada por um único valor de probabilidade: a probabilidade da classe modal  $\omega_c$  ( $c = 1, \dots, m$ ) associada à posição  $\vec{x}_i$ . Essa medida tem a seguinte formulação:

$$Inc(\vec{x}_i) = 1 - P(\omega_c | \vec{x}_i). \quad (25)$$



onde:  $i = 1, \dots, n$ ; e  $P(\omega_c | \bar{x})$  é a probabilidade *a posteriori* do vetor de atributos  $\bar{x}_i$  pertencer à classe considerada.

Como a incerteza varia espacialmente, um mapa de incerteza pode ser mais útil do que uma quantificação global da incerteza, particularmente para um analista que usa o mapa para visualização exploratória ou confirmatória (MACEACHREN, 1994). Uma dessas representações, o mapa bivariado, indica uma relação combinada na qual mapa e qualidade são mostrados em uma única visualização. Embora a exibição bivariada seja complexa e difícil de ser interpretada, provê uma imediata visualização da incerteza, representando uma importante regra na exploração e desenvolvimento de visualização da qualidade do mapa, para a qual um número significativo de técnicas tem sido proposto e aplicado. As exibições bivariadas podem ser estáticas ou dinâmicas. Exemplos de técnicas estáticas são transformações de cor, mistura, foco, superfície de incerteza tridimensional e ofuscamento. Técnicas dinâmicas referem-se a fatiamento, cintilamento, movimento e *zoom* (VAN DER WEL; VAN DER GAAG; GORTE, 1998).

A incerteza derivada de um mapeamento é particularmente percebida nas zonas de transição que ocorrem entre classes, representando ambigüidade de atributo. A mescla de cores (ou tons de cinza) nas zonas misturadas pode corresponder a fronteiras entre tipos de cobertura. A aplicação dessas técnicas pode criar uma impressão de variabilidade contínua entre feições naturais (DRECKI, 2002).

Em uma aproximação dinâmica, a incerteza pode ser representada pelo fatiamento. Nesse método, diferentes valores de limiar podem ser atribuídos para diferenciar a qualidade do mapeamento. A técnica de *zoom* também permite a visualização dinâmica da incerteza sob diferentes perspectivas e esta é baseada na ferramenta de *zoom* disponível em muitos dos aplicativos. Uma visualização distanciada pode ser usada para dado incerto, enquanto para dados de alta confiabilidade utiliza-se uma visão detalhada (DRECKI, 2002).



#### 4 SISTEMAS DE CLASSIFICAÇÃO DE USO E COBERTURA DA TERRA

Antes de falar sobre sistemas de classificação é preciso conceituar cobertura da terra. A definição adotada para esta pesquisa considera que o termo “cobertura da terra” refere-se à cobertura (bio)física observada sobre a superfície terrestre, isto é, àquilo que se pode extrair diretamente de imagens orbitais ou fotografias aéreas. Essa definição é fundamental, visto que, em muitas classificações e legendas existentes, nota-se uma confusão com a denominação “uso da terra”, que pode ser caracterizada pelas atividades desenvolvidas pelas pessoas que ocupam um tipo de cobertura da terra específico e interagem para mantê-lo ou modificá-lo (DI GREGÓRIO, 2004). Assim, por exemplo, as áreas de recreação existentes nas cidades são usos da terra que podem ser aplicados a diferentes tipos de cobertura da terra, desde áreas verdes até áreas construídas.

Torna-se importante destacar também que o termo “terra” é definido no sentido de terra arável, o mesmo que solo agriculturável ou solo (GUERRA, 1993). Em alguns casos, os termos “terra” e “solo” não são considerados sinônimos.

Com a grande diversidade de tipos de cobertura da terra existentes, o homem sentiu a necessidade de descrevê-los mais apropriadamente e classificá-los com vistas ao desenvolvimento de sistemas, incorporando a necessidade crescente de padronizar e compatibilizar os dados para o mapeamento, análise e monitoramento de extensas áreas, de maneira prática e consistente (DI GREGÓRIO, 2004).

Contudo, o que se vê, atualmente, é uma grande quantidade de mapeamentos temáticos com classes inapropriadas para propósitos particulares (por exemplo, necessidades de desenvolvimento urbano e rural), ou com terminologia ambígua, voltados a finalidades específicas, ou com informação, muitas vezes, obsoleta (DI GREGÓRIO, 2004).

Em geral, o que se encontra na literatura são classificações de vegetação ou sistemas relacionados à descrição de feições específicas (por exemplo, áreas agrícolas), os quais são, portanto, limitados na sua capacidade de definir toda a variedade de tipos possíveis de cobertura da terra (DI GREGÓRIO, 2004).

Um sistema de classificação consiste em uma estrutura de representação de classes temáticas em níveis de detalhamento. Para que um sistema de classificação possa ser utilizado como referência, Di Gregório (2004) enfatiza que este deve ter as seguintes características:



- amplo e consistente cientificamente;
- capaz de suprir a necessidade de uma variedade de usuários;
- potencialmente aplicável como um sistema de referência comum e que facilita comparações entre classes derivadas de diferentes classificações;
- flexível, podendo ser usado em diferentes escalas e em diferentes níveis de detalhe, permitindo confrontar mapas globais, continentais, regionais e locais sem perda de informação;
- capaz de descrever a diversidade de características da cobertura da terra, com claras definições dos limites das classes; e
- baseado numa descrição clara e sistemática das classes, onde os critérios usados para defini-las não devem ser ambíguos.

Um sistema de classificação adequado deve ser independente da escala, ou seja, as classes devem ser aplicáveis em qualquer escala ou nível de detalhe; e independente da fonte, isto é, independente dos meios usados para coletar a informação, quer seja através de imagens de satélite, fotografias aéreas, levantamentos de campo ou usando uma combinação de fontes (DI GREGÓRIO, 2004).

Sistemas de classificação podem ser apresentados em dois tipos básicos: hierárquico e não-hierárquico. A maioria dos sistemas é hierarquicamente estruturada, visto que, dessa forma, a classificação oferece maior consistência devido à habilidade de acomodar diferentes níveis de informação, iniciando com as classes mais amplas e, a partir dessas, realizando uma subdivisão sistemática (DI GREGÓRIO, 2004). Assim, em um sistema hierárquico, as classes nos níveis superiores e menos detalhados podem ser divididas em subclasses, nos níveis inferiores e de maior detalhamento. Na Figura 8 é apresentado um sistema hierárquico com três níveis de detalhamento, composto de duas classes no nível I, quatro subclasses no nível II e dez subclasses no nível III.




Figura 8: Sistema hierárquico de classificação com três níveis de detalhamento.

A classificação pode ser feita de duas maneiras: *a priori* ou *a posteriori*. Em um sistema de classificação a priori, as classes são concepções abstratas dos tipos que realmente ocorrem. A definição das classes é estabelecida antes que seja feita qualquer coleta de dados, de modo que se deve prever todas as possíveis ocorrências antes de realizar a classificação. A principal vantagem é que as classes são padronizadas e independentes da área e dos meios utilizados. Contudo, a desvantagem consiste no fato de que se trata de um método rígido, fazendo com que algumas das amostras de campo possam não se categorizar facilmente nas classes pré-definidas (DI GREGÓRIO, 2004; ROBINOVE, 1981).

Por outro lado, a classificação a posteriori agrupa as classes com base nas semelhanças ou diferenças de amostras coletadas em campo. Dessa forma, implica em um mínimo de generalização, sendo o tipo de classificação que melhor ajusta as observações coletadas em campo para uma área específica. A vantagem desse método está na sua flexibilidade e adaptabilidade, quando comparado com a rigidez da classificação *a priori*. Ao mesmo tempo, porém, como uma classificação *a posteriori* depende de uma área específica descrita e é adaptada às condições locais, torna-se incapaz de definir classes padronizadas (DI GREGÓRIO, 2004; ROBINOVE, 1981).

O sistema de classificação a ser considerado deve estar previsto dentro de um projeto (ou esquema) de classificação, o qual deve contemplar a definição das classes temáticas necessárias a aplicação específica; os dados e técnicas de classificação mais adequadas; e o método de análise da qualidade temática da informação representada.

Conforme Congalton e Green (1999), o projeto de classificação contempla dois componentes críticos: (1) um conjunto de rótulos, isto é, dos nomes das classes estabelecidas para o sistema de classificação; e (2) um conjunto de regras ou definições que caracterizem os diferentes tipos de ocorrências a serem mapeados. Sem um claro conjunto de regras, a atribuição dos rótulos aos tipos de cobertura torna-se arbitrária e sem consistência.

Dessa forma, um projeto de classificação é um meio de representar a informação espacial de uma maneira lógica e ordenada, sendo fundamental a qualquer projeto de mapeamento. O projeto de classificação possibilita, para quem produz o mapa, caracterizar as feições da paisagem, e, para o usuário, reconhecê-las. O nível de detalhamento (isto é, número e complexidade das classes) estabelecido no projeto é direcionado pelo uso que será dado à informação representada no mapa e pelos atributos da terra que são discerníveis nos dados utilizados na sua elaboração (CONGALTON; GREEN, 1999).

Normalmente, cada usuário define sua própria legenda da classificação contendo as classes de uso e cobertura da terra de interesse, visto que não existe um sistema





de classificação padrão. A legenda consiste na aplicação de uma classificação em uma área específica usando uma escala de mapeamento (ou escala cartográfica) definida e um conjunto de dados específico. Quando uma legenda é definida a partir de um sistema de classificação, esta pode conter apenas um subconjunto de todas as classes possíveis estabelecidas nesse sistema. Conforme Di Gregório (2004), a legenda é dependente da escala e da representação cartográfica, bem como dos dados e do método de mapeamento.

IBGE (2006a) afirma que é esperado que os mapeamentos de uso e cobertura da terra forneçam informações sobre o território ao maior número possível de usuários, em diferentes escalas, de tal forma que possam ser comparados entre si e periodicamente atualizados. Para atender esses requisitos, Heymann<sup>7</sup> (1994 apud IBGE, 2006a) recomenda a observância de quatro princípios básicos para esses mapeamentos:

- a natureza da informação básica: deve-se ter ciência dos tipos de dados necessários à informação que se deseja extrair, sejam eles imagens orbitais ou outros. O tipo e a quantidade de informação obtida dependem das características desses dados (IBGE, 2006a);
- a unidade de mapeamento e a definição da menor área a ser mapeada: a unidade de mapeamento é a representação da homogeneidade e diversidade de objetos que recobrem a superfície terrestre, ou seja, definida pelas classes temáticas, e está intrinsecamente relacionada à resolução espacial do sensor (IBGE, 2006a). O tamanho da área mínima a ser representada como pertencente a uma determinada classe dependerá da escala e resolução dos dados originais do sensor ou da fonte a partir da qual a informação é identificada e interpretada (ANDERSON et al., 1976);
- a nomenclatura: a construção da nomenclatura das classes deve ser adequada para mapear a diversidade da região considerada e deve ser compatível com a escala, o tamanho da menor área a ser mapeada, a fonte básica dos dados e com as necessidades dos usuários (IBGE, 2006a);
- a escala de mapeamento: a concepção de um método para levantamento e mapeamento do uso e cobertura da terra, visando atingir diferentes tipos de usuários e propósitos, deve prever a reprodução da informação em diferentes escalas, a fim de ser utilizada em vários níveis de tomada de decisão (IBGE, 2006a).

---

<sup>7</sup> HEYMANN, Y. **Corine land cover technical guide**. Luxembourg: European Commission, 1994.



#### 4.1 Sistemas de classificação para mapeamento em escala regional

Conforme destacam Caetano, Santos e Gonçalves (2002), diversos países têm feito uso de imagens de satélite para mapear a superfície terrestre. Conseqüentemente, há uma diversidade de programas de cartografia, os quais utilizam imagens orbitais para a representação do uso e da cobertura do território. Dentre os programas existentes, alguns foram caracterizados, pelos citados autores, quanto ao número de classes; formato dos dados; unidade mínima (ha<sup>8</sup>); imagem de satélite utilizada; metodologia adotada; e região de abrangência (Tabela 5).

Tabela 5: Caracterização de programas de cartografia do uso e cobertura da terra.

| <i>Programa</i>   | <i>Número de classes</i> | <i>Formato dos dados</i> | <i>Unidade mínima (ha)</i> | <i>Imagem de satélite</i> | <i>Método</i>                                     | <i>Região de abrangência</i>        |
|---|--------------------------|--------------------------|----------------------------|---------------------------|---|-------------------------------------|
| <i>North American Landscape Characterization (NALC)</i>     | 16                       | Matricial                | 0,36                       | Landsat MSS               | Classificação não supervisionada e análise visual | América do Norte                    |
| <i>National Land Cover Characterization (NLCD)</i>          | 21                       | Matricial                | 0,09                       | Landsat TM                | Classificação não supervisionada                  | 48 Estados contínuos dos EUA        |
| <i>Kansas State Land Use/Land Cover Map</i>                 | 10                       | Vetorial                 | Aprox. 1                   | Landsat TM                | Classificação não supervisionada e edição manual  | Estado do Kansas, EUA               |
| <i>California Land Cover Mapping and Monitoring Program</i> | 44                       | Vetorial                 | aprox. 1,2                 | Landsat TM                | Classificação, segmentação e reclassificação      | Estado da Califórnia, EUA           |
| <i>North Carolina State Land Cover Map</i>                  | 22                       | Matricial                | 0,97 e 0,49 (água)         | Landsat TM                | Classificação de imagens com método híbrido       | Estado da Carolina do Norte, EUA    |
| <i>Ontario Cover Map</i>                                    | 28                       | Matricial                | 0,5                        | Landsat TM                | Classificação supervisionada                      | Província de Ontário, Canadá        |
| <i>South African National Land Cover Database (NLC)</i>     | 31                       | Vetorial                 | 25                         | Landsat TM                | Análise visual                                    | África do Sul, Suazilândia e Lesoto |
| <i>CORINE Land Cover</i>                                    | 44                       | Vetorial                 | 25                         | Landsat TM                | Análise visual                                    | Europa                              |
| <i>Finnish land use and forest classification</i>           | 50                       | Matricial                | 0,06                       | Landsat TM                | Classificação supervisionada                      | Finlândia                           |

<sup>8</sup> O hectare (ha) é uma unidade de medida de área, onde 1 hectare equivale a 10.000 m<sup>2</sup>.



|  |    |           |      |                      |                                |              |
|--|----|-----------|------|----------------------|--------------------------------|--------------|
| <i>Swedish Terrain Type Classification</i> | 13 | Matricial | 0,06 | Landsat TM e SPOT XS | Classificação e análise visual | Suécia       |
| <i>Land cover map of Great Britain</i>     | 25 | Vetorial  | 0,06 | Landsat TM           | Classificação supervisionada   | Grã Bretanha |

Fonte: CAETANO; SANTOS; GONÇALVES (2002).

Caetano, Santos e Gonçalves (2002) fizeram uma análise desses programas e verificaram que:

- a maior parte dos produtos cartográficos é gerada com imagens TM/Landsat, provavelmente em consequência do seu preço reduzido se comparado com outras imagens com especificações técnicas semelhantes;
- as técnicas utilizadas baseiam-se tanto em análise visual quanto em classificação digital. Contudo, grande parte das técnicas que utilizam análise quantitativa tem uma fase de edição manual na etapa final de mapeamento, a fim de corrigir erros na atribuição dos *pixels* às classes;
- a produção cartográfica, apesar de ter imagens de satélite como informação base, também recorre a outros tipos de informação (fotografia aérea, cartas de solos, modelos digitais de terreno e/ou levantamento de campo) que visam melhorar os resultados alcançados com o processamento digital;
- o período médio para atualização dos produtos gerados é de 10 a 15 anos;
- as especificações técnicas referentes à nomenclatura, área mínima e escala são distintas, embora a informação de base seja semelhante (isto é, Landsat); e
- não existe um método padrão para produção cartográfica de uso e cobertura da terra com imagens de satélite.

Como ficou evidente, a quantidade de programas voltados ao mapeamento temático é grande. Visto que não existe uma padronização de classes, escalas e/ou níveis de detalhamento, nota-se incompatibilidades entre os sistemas de classificação e legendas utilizadas.

Anderson et al. (1976) já destacavam, naquela época, a necessidade de padronização entre os sistemas de classificação. Conforme os autores, agências em vários níveis governamentais coletavam dados sobre a terra, mas, na maioria, os trabalhos eram feitos sem interligação entre esses órgãos, o que implicava na duplicação de esforços.

A demanda por padronização de dados de uso e cobertura da terra aumenta conforme se busca avaliar e gerenciar áreas de preocupação crítica para controle ambiental,



como, por exemplo, áreas de produção e desenvolvimento de fontes de energia, que requerem um planejamento cuidadoso (ANDERSON et al., 1976).

Dentre os sistemas de classificação consultados na literatura, destaque será dado, nesta pesquisa, ao sistema proposto por Anderson et al. (1976) e utilizado pelo Serviço Geológico dos Estados Unidos (*United States Geological Survey* – USGS), e também ao sistema de classificação do Projeto CORINE *Land Cover*. Outros enfoques desta pesquisa, a nível nacional, são o Projeto de Uso da Terra elaborado pelo IBGE (Instituto Brasileiro de Geografia e Estatística) e o Manual Técnico da Vegetação Brasileira (IBGE, 1992b). A seleção desses quatro sistemas se deve aos seguintes fatos: (1) tratam-se de sistemas reconhecidos na literatura clássica; (2) a maior parte destes propõe uma hierarquização na representação das classes; e (3) são amplos, isto é, abrangem uma variedade de tipos de uso e cobertura da terra.

#### **4.1.1 Sistema utilizado pelo Serviço Geológico dos Estados Unidos (USGS)**

Anderson et al. (1976) definiram um sistema de classificação de uso e cobertura da terra para ser utilizado a partir de sensores orbitais. Esse sistema foi apresentado e publicado no Documento Técnico 964 do Serviço Geológico dos Estados Unidos e, conforme Robinove (1981), foi utilizado pelo USGS para mapear o uso e a cobertura da terra dos Estados Unidos nas escalas 1:250.000 e 1:100.000.

Os autores desse sistema procuraram compatibilizar as diferentes categorias de uso e cobertura da terra com as características dos objetos que pudessem ser definidas através das imagens de sensoriamento remoto. Anderson et al. (1976) afirmaram que a ênfase em imagens orbitais como a fonte de dados primária foi a principal distinção entre esse sistema de classificação e os demais existentes na época.

O sistema hierárquico proposto inclui apenas os níveis I e II (Tabela 6), principalmente de interesse a usuários que desejam informação em uma base de âmbito nacional, interestadual ou estadual. Corresponde a um sistema propositalmente aberto, permitindo flexibilidade para o desenvolvimento posterior de classificação mais detalhada, nos níveis III e IV, os quais podem ser utilizados para fornecer informação em uma resolução apropriada para atividades de planejamento e gerenciamento regionais, locais ou nacionais (ANDERSON et al., 1976; LILLESAND; KIEFER; CHIPMAN, 2004).



Tabela 6: Sistema desenvolvido por Anderson et al. (1976) e utilizado pelo USGS.

| NÍVEL I                      | NÍVEL II  |
|------------------------------|---|
| 1 Terra urbana ou construída | 1.1 Residencial<br>1.2 Comercial e serviços<br>1.3 Industrial<br>1.4 Transportes, comunicações e utilidades<br>1.5 Complexos industriais e comerciais<br>1.6 Terra urbana ou construída mista<br>1.7 Outro tipo de terra urbana ou construída |
| 2 Terra agrícola             | 2.1 Terra de cultivo e pastagem<br>2.2 Pomares, bosques, vinhedos, viveiros e áreas de horticultura ornamental<br>2.3 Atividades de alimentação confinada<br>2.4 Outro tipo de terra agrícola   |
| 3 Pastagem                   | 3.1 Pastagem herbácea<br>3.2 Pastagem com arbusto e carrasco<br>3.3 Pastagem mista  |
| 4 Terra de floresta          | 4.1 Terra de floresta decídua<br>4.2 Terra de floresta sempre verde<br>4.3 Terra de floresta mista  |
| 5 Água                       | 5.1 Cursos d'água e canais<br>5.2 Lagos<br>5.3 Reservatórios<br>5.4 Baías e estuários   |
| 6 Terra úmida                | 6.1 Terra úmida florestada<br>6.2 Terra úmida não florestada  |
| 7 Terra árida                | 7.1 Planícies salgadas secas<br>7.2 Praias<br>7.3 Outras áreas de areia além de praias<br>7.4 Rocha exposta<br>7.5 Minas a céu-aberto, pedreiras e minas de cascalho<br>7.6 Áreas de transição<br>7.7 Terra árida mista                       |
| 8 Tundra                     | 8.1 Tundra de arbusto e macega<br>8.2 Tundra herbácea<br>8.3 Tundra de solo nu<br>8.4 Tundra úmida<br>8.5 Tundra mista  |
| 9 Neve ou gelo perene        | 9.1 Campos de neve perene<br>9.2 Geleiras   |

Fonte: ANDERSON et al. (1976).

Dessa forma, os usuários não devem considerar-se limitados às categorias listadas na Tabela 6, mas, a partir dessas, devem desenvolver as próprias categorias de máxima utilidade para suas necessidades particulares (ANDERSON et al., 1976). Nesse sentido, Lillesand, Kiefer e Chipman (2004) destacam que um número de esforços de mapeamento de uso e cobertura da terra, mais recentes, mais detalhados e/ou mais especializados, segue a estrutura básica do sistema proposto para o USGS.



Para cada nível de detalhamento foi recomendada a resolução espacial adequada para a representação das informações, como pode ser visto na Tabela 7, organizada por Aronoff (2005). Para os níveis III e IV, informação adicional é necessária, a fim de poder representar corretamente as categorias. Assim, quanto mais detalhado for o nível de categorização, maior será a dependência de dados de sensoriamento remoto de maior resolução e de uma maior quantidade de dados auxiliares (ANDERSON et al., 1976).

Tabela 7: Instrumentos sensores e resoluções espaciais recomendadas para o mapeamento dos níveis propostos por Anderson et al. (1976).

| USGS nível | Escala de mapeamento | Resolução espacial nominal | Instrumentos sensores multiespectrais   |
|------------|----------------------|----------------------------|---|
| I          | 1:500.000            | > 20 m                     | Landsat ETM+, SPOT HRV/HRG, SPOT VMI, NOAA AVHRR, IRS LISS, Terra ASTER, Aqua/Terra MODIS |
| II         | 1:50.000             | 5-20 m                     | Terra ASTER (bandas do visível), Landsat ETM+*, SPOT HRV/HRG*                             |
| III        | 1:25.000             | 1-5 m                      | IKONOS, QuickBird, OrbView 3  |
| IV         | 1:10.000             | < 1 m                      | Imagens de resolução espacial fina  |

\* Sob condições ideais (imagens claras, alto contraste dos alvos da superfície) é possível obter uma classificação satisfatória para o nível II para a maioria das classes a partir de dados ETM+ e HRV/HRG.

Fonte: ARONOFF (2005).

#### 4.1.2 Sistema proposto pelo Projeto CORINE Land Cover

O Programa CORINE (*Coordination of Information on the Environment – Coordenação de Informação do Ambiente*) foi implementado pela Agência Ambiental Européia (*European Environment Agency – EEA*), no período de 1985 a 1990, e surgiu da necessidade de se ter uma base de informações ambientais de todo o território europeu, de forma homogênea e suscetível a atualizações periódicas (BÜTTNER et al., 2004).

O banco de dados do Projeto CORINE Land Cover (CLC), criado em 1985, é parte do Programa CORINE e foi utilizado para a elaboração de uma carta temática de uso e ocupação do solo para toda Europa, em 1990 (CLC90), com base na interpretação visual de imagens de satélites e em informações auxiliares (BÜTTNER et al., 2002).

Com o passar dos anos, vários usuários europeus e internacionais expressaram a necessidade de atualização do CLC90. Assim, fruto dessa necessidade de atualização surgiu o Projeto I&CLC2000, o qual consiste de dois componentes principais interconectados: (1) IMAGE2000, que abrange as atividades relacionadas à aquisição de



imagens de satélite, ortorretificação e mosaicagem; e (2) CLC2000, responsável pela atualização do CLC90 (BÜTTNER et al., 2004).

A metodologia padrão proposta no CLC90, baseada em interpretação visual assistida por computador, continuou a ser adotada para o CLC2000, utilizando-se imagens do sensor ETM+/Landsat complementadas com dados auxiliares advindos de mapas topográficos e fotografias aéreas. Conforme Büttner et al. (2004), as especificações técnicas do Projeto CORINE *Land Cover* são: escala cartográfica de 1:100.000; unidade mínima de mapeamento igual 25 ha; e o espaçamento mínimo entre as linhas é de 100 m.

A nomenclatura desse sistema de classificação é hierarquizada em três níveis e pode ser vista na Tabela 8. O primeiro nível compreende as maiores categorias de cobertura da terra para o planeta; o segundo nível é utilizado para escalas de 1:1.000.000 a 1:500.000; e o terceiro nível deverá ser utilizado em projetos na escala 1:100.000. Um quarto nível poderá ser adicionado e corresponderá a informações mais detalhadas e em escalas maiores, a partir da derivação de categorias do terceiro nível (EEA, 1995).

Tabela 8: Sistema proposto pelo Projeto CORINE Land Cover.

| NÍVEL I                   | NÍVEL II   | NÍVEL III  |
|---------------------------|--|--|
| 1 Superfícies Artificiais | 1.1 Estruturas urbanas                               | 1.1.1 Estruturas urbanas contínuas<br>1.1.2 Estruturas urbanas descontínuas  |
|                           | 1.2 Unidades industriais, comerciais e de transporte | 1.2.1 Unidades industriais ou comerciais<br>1.2.2 Rodovias e ferrovias e feições associadas<br>1.2.3 Áreas portuárias<br>1.2.4 Aeroportos  |
|                           | 1.3 Locais de minas, de depósitos e de construção    | 1.3.1 Locais de extração mineral<br>1.3.2 Locais de depósitos de lixo<br>1.3.3 Locais de construção  |
|                           | 1.4 Áreas vegetadas artificiais e não-agrícolas      | 1.4.1 Áreas verdes urbanas<br>1.4.2 Instalações para esporte e lazer   |
| 2 Áreas agrícolas         | 2.1 Terras aráveis                                   | 2.1.1 Terras aráveis não-irrigadas<br>2.1.2 Terras permanentemente irrigadas<br>2.1.3 Campos de arroz  |
|                           | 2.2 Culturas permanentes                             | 2.2.1 Vinhedos<br>2.2.2 Árvores frutíferas e plantações de fruto silvestre<br>2.2.3 Bosques de oliveiras   |
|                           | 2.3 Pastagens  | 2.3.1 Pastagens  |
|                           | 2.4 Áreas agrícolas heterogêneas                     | 2.4.1 Culturas anuais associadas com culturas permanentes<br>2.4.2 Padrões de cultivo complexo<br>2.4.3 Terras ocupadas principalmente por agricultura, com áreas significativas de vegetação natural<br>2.4.4 Áreas agrofloretais |

|                                   |  |   |
|-----------------------------------|--|---|
| 3 Florestas e áreas semi-naturais | 3.1 Florestas                                      | 3.1.1 Florestas com folhas largas<br>3.1.2 Florestas de coníferas<br>3.1.3 Florestas mistas   |
|                                   | 3.2 Associações de vegetação herbácea /arbustiva   | 3.2.1 Campos naturais<br>3.2.2 Urzais e charnecas<br>3.2.3 Vegetação mediterrânea de <i>Sclerophyllous</i><br>3.2.4 Transição arbusto/bosque                |
|                                   | 3.3 Espaços abertos com pouca ou nenhuma vegetação | 3.3.1 Praias, dunas e areais<br>3.3.2 Afloramentos rochosos<br>3.3.3 Áreas com vegetação esparsa<br>3.3.4 Áreas queimadas<br>3.3.5 Geleiras e neves perenes |
| 4 Áreas úmidas                    | 4.1 Áreas úmidas interiores                        | 4.1.1 Pântanos interiores<br>4.1.2 Turfeiras  |
|                                   | 4.2 Áreas úmidas litorâneas                        | 4.2.1 Pântanos salinos<br>4.2.2 Salinas<br>4.2.3 Planícies intermarés   |
| 5 Corpos d'água                   | 5.1 Águas interiores                               | 5.1.1 Cursos d'água<br>5.1.2 Corpos d'água  |
|                                   | 5.2 Águas marinhas                                 | 5.2.1 Lagunas costeiras<br>5.2.2 Estuários<br>5.2.3 Mares e oceanos   |

Fonte: BÜTTNER et al. (2004).

Recentemente, uma nova atualização do CORINE *Land Cover* (CLC2006) foi proposta visando a geração de um mapeamento atualizado, com imagens orbitais do ano de 2006, e cujo término era esperado para o final do ano de 2008. Nesse caso, as imagens do satélite Landsat foram substituídas por imagens SPOT-4, SPOT-5 e IRS-P6 LISS III. Contudo, as mesmas classes listadas na Tabela 8 (CAETANO; SANTOS; GONÇALVES, 2002) e utilizadas no CLC2000 foram mantidas para a geração desse novo mapeamento, a fim de detectar as mudanças ocorridas entre os tipos de cobertura da terra, nos períodos analisados.

#### 4.1.3 Sistema proposto pelo Projeto de Uso da Terra do IBGE

A ausência de trabalhos que pudessem servir como um referencial nacional para o estabelecimento de normas e critérios a serem utilizados na elaboração de mapeamentos de uso e cobertura da terra indicou a necessidade da elaboração de um sistema que pudesse atender a esse objetivo. Com isso, o IBGE elaborou uma primeira aproximação de um sistema de classificação de uso e cobertura da terra, cujos objetivos gerais foram o





recobrimento do país em termos da classificação dos tipos de cobertura e uso, a análise dos impactos e a definição dos indicadores da qualidade ambiental (IBGE, 1999a).

A metodologia utilizada por IBGE (1999a) para caracterizar as classes seguiu um procedimento de mapeamento em escalas crescentes, sendo essas: “exploratória” (1:2.500.000 até 1:1.000.000); de “reconhecimento” (1:250.000 até 1.000.000); de “semi-detalle” (1:100.000 até 1:25.000); e de “detalle” (> 1:25.000) (Tabela 9). O levantamento “ultra-detalhado”, em geral, é executado para atendimento de propósitos específicos, sendo, na maioria das vezes, desenvolvido em escalas grandes (1:5.000; 1:2.000; 1:500).

Tabela 9: Procedimento de mapeamento definido no Manual Técnico de Uso da Terra.

| 1: 2.500.000 a<br>1: 1.000.000                                      | 1: 1.000.000 a<br>1: 250.000  | 1: 100.000 a<br>1: 25.000   | < 1: 25.000   |
|---|---|---|---|
| Indicação das classes de uso dominante ou de associação de classes. | Indicação das classes e tipos dominantes ou associações dominantes. | Indicação das classes, tipos e subtipos dominantes ou associações dominantes. | Indicação das classes, tipos, subtipos e espécies dominantes ou associações dominantes.                               |
| Exemplo   |   |   |   |
| Agricultura   | Agricultura tradicional   | Agricultura tradicional com culturas permanentes                              | Agricultura de subsistência com cultivo de mandioca   |
| Pecuária  | Pecuária extensiva  | Pecuária extensiva com finalidade de corte                                    | Pecuária extensiva com finalidade de corte e criação de gado bovino   |
| Agricultura + Pecuária  | Agricultura tradicional + Agropecuária                              | Agricultura tradicional com culturas cíclicas + Agropecuária                  | Agricultura tradicional com culturas cíclicas com cultivo de milho + Agropecuária com cultura de sorgo de gado bovino |

Fonte: Adaptado de IBGE (1999a).

IBGE (1999a) comenta que os levantamentos de uso e cobertura da terra envolvem pesquisa de gabinete e campo, registro de observações e análise. O material utilizado nesses levantamentos consiste, normalmente, de produtos de sensores orbitais, fotografias aéreas e mapas topográficos. A escala do material deve ser compatível com o nível de detalhamento ou generalização desejada e prevista para ser apresentada no mapa final.

Conforme IBGE (1999a), no Brasil podem ser identificadas, basicamente, sete classes de uso da terra, sendo essas: agricultura, pecuária, agropecuária, extrativismo, mineração, áreas especiais e áreas urbanas. Essas classes podem ser subdivididas em tipos de subtipos, conforme a Tabela 10.



Tabela 10: Classes, tipos e subtipos de uso da terra.

| CLASSES | TIPOS | SUBTIPOS  | DESCRIÇÃO  |
|---------|-------|---|--|
| A       | AS    | AS  | Agricultura de Subsistência                                    |
|         | AT    | ATp   | Agricultura Tradicional com culturas permanentes               |
|         |       | ATc   | Agricultura Tradicional com culturas cíclicas                  |
|         |       | ATpc  | Agricultura Tradicional com cultivo misto                      |
|         | ATr   | ATrp  | Agricultura de Transição com culturas permanentes              |
| ATrc    |       | Agricultura de Transição com culturas cíclicas    |  |
| ATrpc   |       | Agricultura de Transição com cultivo misto        |  |
| AM      | AMp   | Agricultura Modernizada com cultura permanente    |  |
|         | AMc   | Agricultura Modernizada com cultura cíclica       |  |
|         | AMpc  | Agricultura Modernizada com cultivo misto         |  |
|         | AMaf  | Agricultura Modernizada com cultivo agroflorestal |  |
| R/F     | R     | Reflorestamento com espécies exóticas             |  |
|         | F     | Florestamento com espécies exóticas               |  |
|         | Rn    | Reflorestamento com espécies nativas              |  |
|         | Fn    | Florestamento com espécies nativas                |  |
| P       | PE    | PEc   | Pecuária Extensiva com finalidade de corte                     |
|         |       | PEcl  | Pecuária Extensiva com finalidade mista                        |
|         | OS    | PSc   | Pecuária Semi-Intensiva com finalidade de corte                |
| PSI     |       | Pecuária Semi-Intensiva com finalidade de leite   |  |
| PScl    |       | Pecuária Semi-Intensiva com finalidade mista      |  |
| PI      | PIc   | Pecuária Intensiva com finalidade de corte        |  |
|         | PII   | Pecuária Intensiva com finalidade de leite        |  |
|         | PIcl  | Pecuária Intensiva com finalidade mista           |  |
| AP      | APs   | APs   | Agropecuária de subsistência                                   |
|         | AP    | AP  | Agropecuária   |
| E       | EV    | EV  | Extrativismo Vegetal   |
|         | EA    | EA  | Extrativismo Animal  |
|         | EM    | EM  | Extrativismo Mineral   |
| M       | MCA   | MCA   | Mineração Organizada a Céu Aberto                              |
|         | MSS   | MSS   | Mineração Organizada em Sistema Subterrâneo                    |
| AE      | AER   | AER   | Áreas Especiais com destinação para Reservas                   |
|         | AEP   | AEP   | Áreas Especiais com destinação para Parques                    |
|         | AEF   | AEF   | Áreas Especiais com destinação para Florestas                  |
|         | AEA   | AEA   | Áreas Especiais com destinação para Área de Proteção Ambiental |
|         | AEE   | AEE   | Áreas Especiais com destinação para Estação Ecológica          |
| AU      | AUR   | AUR   | Áreas Urbanas Residenciais                                     |
|         | AUC   | AUC   | Áreas Urbanas Comerciais                                       |
|         | AUI   | AUI   | Áreas Urbanas Industriais                                      |
|         | AUCi  | AUCi  | Complexos Industriais e Comerciais                             |
|         | AUM   | AUM   | Terras Urbanas de Uso Misto                                    |

Fonte: IBGE (1999a).

Como pode ser visto, nesse primeiro momento, basicamente o uso da terra foi contemplado pelo sistema. Contudo, IBGE (2006a) apresenta uma versão atualizada do sistema proposto, a qual contempla não apenas o uso, mas também a cobertura da terra. Essa nova versão teve como principais bases teóricas os sistemas propostos por Anderson et al. (1976) e pelo Projeto CORINE *Land Cover*.



O sistema de classificação atualizado do IBGE foi definido com três níveis hierárquicos, como classes e subclasses, procurando formar legendas com o máximo de significado e o mínimo de níveis. IBGE (2006a) destaca que o nível I indica as principais classes de cobertura terrestre no planeta, que podem ser discriminadas via interpretação de imagem, sendo empregado em escalas globais. A cobertura no nível II, em escala regional, também pode ser extraída a partir de sensores orbitais e utilizada para mapeamentos na escala 1:250.000. O nível III exige a incorporação de dados auxiliares, além daqueles obtidos com sensores orbitais, podendo gerar mapeamentos na escala 1:100.000.

Em IBGE (2004a), IBGE (2005) e IBGE (2006b), classes de uso da terra foram definidas com base em IBGE (1999a) e também foi apresentada nova nomenclatura para contemplar a descrição da cobertura da terra, sendo utilizada no mapeamento dos Estados do Amapá, de Roraima e do Acre, respectivamente.

Na versão atualizada do sistema de classificação proposto pelo Projeto de Uso da Terra, verifica-se a coincidência existente entre os níveis I e II com o que tinha sido apresentado em IBGE (2004a). As mesmas classes apresentadas nesses dois níveis foram mantidas em IBGE (2006a) e, para o nível III, Santos (2006) apresentou uma sintetização em relação às classes de uso da terra descritas em IBGE (1999a). Na Tabela 11 pode ser visto o sistema do Projeto de Uso da Terra disponibilizado por Santos (2006), o qual contempla, além do uso, classes de cobertura da terra.

Tabela 11: Sistema proposto no Projeto de Uso da Terra do IBGE.

| NÍVEL I                          | NÍVEL II                 | NÍVEL III  |
|----------------------------------|--------------------------|--|
| 1 Áreas antrópicas não agrícolas | 1.1 Áreas urbanizadas    | 1.1.1 Cidades  |
|                                  | 1.2 Áreas de mineração   | 1.2.1 Lavra a céu aberto<br>1.2.2 Lavra subterrânea<br>1.2.3 Garimpo a céu aberto e/ou em leito de rios<br>1.2.4 Garimpo subterrâneo |
| 2 Áreas antrópicas agrícolas     | 2.1 Culturas temporárias | 2.1.1 Cultivos de subsistência<br>2.1.2 Cultivos tradicionais<br>2.1.3 Cultivos comerciais e industriais                             |
|                                  | 2.2 Culturas permanentes | 2.2.1 Cultivos de subsistência<br>2.2.2 Cultivos tradicionais<br>2.2.3 Cultivos comerciais e industriais                             |
|                                  | 2.3 Pastagem             | 2.3.1 Pecuária semi-intensiva<br>2.3.2 Pecuária intensiva  |
|                                  | 2.4 Silvicultura         | 2.4.1 Florestamento<br>2.4.2 Cultivo agroflorestal<br>2.4.3 Reflorestamento  |

|                              |                  |  |
|------------------------------|------------------|--|
| 3 Áreas de vegetação natural | 3.1 Florestal    | 3.1.1 Unidades de Conservação de uso integral<br>3.1.2 Unidades de Conservação de uso sustentado<br>3.1.3 Terra indígena<br>3.1.4 Extrativismo vegetal<br>3.1.5 Extrativismo animal<br>3.1.6 Agricultura de subsistência<br>3.1.7 Pecuária extensiva |
|                              | 3.2 Campestre    | 3.2.1 Unidades de Conservação de uso integral<br>3.2.2 Unidades de Conservação de uso sustentado<br>3.2.3 Terra indígena<br>3.2.4 Extrativismo vegetal<br>3.2.5 Extrativismo animal<br>3.2.6 Agricultura de subsistência<br>3.2.7 Pecuária extensiva |
| 4 Águas                      | 4.1 Continentais | 4.1.1 Aqüicultura<br>4.1.2 Pesca<br>4.1.3 Energia<br>4.1.4 Transporte<br>4.1.5 Lazer e desporto<br>4.1.6 Captação<br>4.1.7 Receptor  |
|                              | 4.2 Costeiras    | 4.2.1 Aqüicultura<br>4.2.2 Pesca<br>4.2.3 Transporte<br>4.2.4 Lazer e desporto<br>4.2.5 Captação<br>4.2.6 Receptor   |

Fonte: SANTOS (2006).

#### 4.1.4 Sistema apresentado no Manual Técnico da Vegetação Brasileira

Ao fazer uma investigação ao longo da história é possível encontrar diversos sistemas de classificação de vegetação. No Brasil, como em outras partes do mundo, existe uma gama de nomenclaturas para designar uma mesma tipologia vegetacional. Primeiramente, existe uma evolução histórica dos nomes atribuídos às diferentes tipologias, que vão desde Martius, nos anos 1840 a 1906, até George Eiten, na década de 1980. Isso citando somente a classificação brasileira propriamente dita, sem considerar adequações a padrões internacionais.

Na década de 1970, contudo, o grupo do Projeto RADAM (Radar na Amazônia) adotou o que ElleMBERG e Mueller-Dumbois propuseram para a UNESCO. Ao longo dos dez anos seguintes, as várias tentativas de classificação da vegetação brasileira



sofreram alterações que culminaram com a apresentação do trabalho intitulado “*Classificação fisionômico-ecológica das formações neotropicais*”, proposto por Veloso e Góes-Filho, em 1982 (IBGE, 1991). Posteriormente, em 1991, esse trabalho foi adotado pelo IBGE, o qual intitulou-se “*Classificação da vegetação brasileira, adaptada a um sistema universal*” (IBGE, 1992a), e, no ano seguinte, essa publicação foi reeditada dando origem ao “Manual Técnico da Vegetação Brasileira” (IBGE, 1992b), porém, mantendo a mesma estrutura de classes de vegetação.

IBGE (1992b) divide a classificação da vegetação brasileira em quatro agrupamentos: (i) Regiões Fitoecológicas; (ii) Formações Pioneiras; (iii) Refúgios Vegetacionais; e (iv) faixas de Tensão Ecológica dos contatos entre duas ou mais Regiões Fitoecológicas. O esquema de classificação das Regiões Fitoecológicas brasileiras é apresentado na Tabela 12, onde verifica-se que são consideradas cinco classes de formações principais: Floresta, Campinarana, Savana, Savana-estépica e Estepe. A distinção entre as classes é baseada nos tipos de plantas que são encontrados em cada uma dessas Regiões Fitoecológicas.

Tabela 12: Esquema da classificação das Regiões Fitoecológicas brasileiras.

| <i>Formações</i>  |  |  |  |
|---|--|--|--|
| <i>Estrutura</i>  | <i>Clima / Déficit hídrico</i>   | <i>Fisionomia</i>                                      | <i>Fisionomia específica</i>                           |
| FLORESTA  | Ombrófila<br>(0 a 4 meses secos)                                       | Densa  | Dossel uniforme<br>Dossel emergente                    |
|   |  | Aberta   | Com palmeiras<br>Com cipó<br>Com bambu<br>Com sororoca |
|   |  | Mista  | Dossel uniforme<br>Dossel emergente                    |
|   | Estacional<br>(4 a 6 meses secos<br>ou com 3 meses<br>abaixo de 15 °C) | Semidecidual<br>Decidual                               | Dossel uniforme<br>Dossel emergente                    |
| CAMPINARANA<br>(Campina)  | Ombrófila<br>(0 a 2 meses secos)                                       | Florestada<br>Arborizada<br>Gramíneo-Lenhosa           | Com palmeiras<br>Sem palmeiras                         |
| SAVANA<br>(Cerrado)   | Estacional<br>(0 a 6 meses secos)                                      | Florestada<br>Arborizada<br>Parque<br>Gramíneo-Lenhosa | Com floresta de galeria<br>Sem floresta de galeria     |
| SAVANA-ESTÉPICA<br>(Caatinga do sertão<br>árido, Chaco sul-mato-<br>grossense, Campos de<br>Roraima e Parque de<br>Espinilho da Barra do<br>Rio Quarai) | Estacional<br>(mais de 6 meses secos<br>ou com frio rigoroso)          | Florestada<br>Arborizada<br>Parque<br>Gramíneo-Lenhosa | Com floresta de galeria<br>Sem floresta de galeria     |

|   |   |  |  |
|---|---|--|--|
| ESTEPE<br>(Campanha gaúcha e<br>Campos meridionais) | Estacional<br>(3 meses frios e<br>1 mês seco) | Arborizada<br>Parque<br>Gramíneo-Lenhosa | Com floresta de galeria<br>Sem floresta de galeria |
|---|---|--|--|

*Fonte: Adaptado de IBGE (1992b).*

Com relação às Formações Pioneiras, estas são subdivididas em três tipos: (i) Vegetação com Influência Marinha, incluindo as restingas; (ii) Vegetação com Influência Fluviomarina, incluindo os manguezais e os campos salinos; e (iii) Vegetação com Influência Fluvial, que engloba as comunidades aluviais caracterizadas por pântanos e planícies alagáveis.

Os Refúgios Vegetacionais referem-se às comunidades relíquias, ou seja, àquelas que apresentam características peculiares diferentes das demais, constituindo refúgios ecológicos. Como exemplo, pode-se mencionar as comunidades vegetacionais localizadas em altitudes acima de 1.800 m.

Por último, destaca-se as faixas de Tensão Ecológica dos contatos entre duas ou mais Regiões Fitoecológicas, isto é, áreas de vegetação de transição. Essas regiões podem caracterizar ecótonos (“mosaicos específicos”), ou seja, misturas florísticas entre tipos de vegetação, ou encaves, onde áreas disjuntas de vegetação se contatam (“mosaicos de áreas edáficas”).

## 4.2 Sistemas de classificação para mapeamento em escala urbana

Existem diversas legendas, definidas por diferentes tipos de usuários, para mapeamentos em escala urbana. Essas legendas, normalmente, são adequadas às necessidades específicas de cada mapeamento e algumas delas apresentam uma hierarquização de classes, como na proposta de Galo, Imai e Ennes (2006), que adaptaram um sistema de classificação para ambientes urbanos a partir de Jensen (2000) (Figura 9). Verifica-se, na hierarquia proposta, que foram considerados diferentes níveis de detalhamento, os quais estão intrinsecamente relacionados à qualidade dos dados que se tem disponível. À medida que se tem um aumento na resolução espacial das imagens é possível individualizar os alvos urbanos para o nível IV da hierarquia.



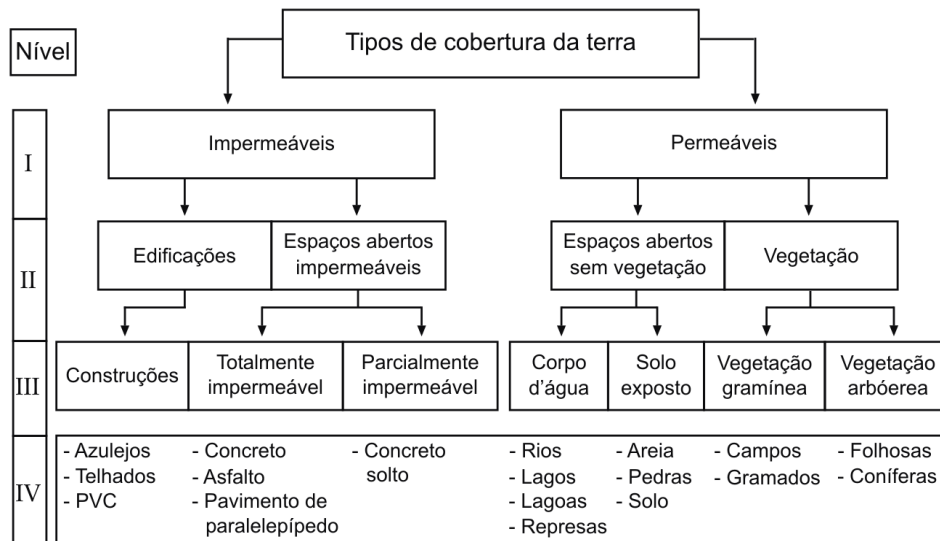


Figura 9: Hierarquia de classes para ambientes urbanos, adaptada por Galo, Imai e Ennes (2006).

Uma proposta de hierarquização comparece também na concepção da FAO (Organização das Nações Unidas para a Agricultura e Alimentação), proposta por Di Gregório (2004). Esse autor insere a classificação de áreas urbanas no contexto de *Superfícies Artificiais e Áreas Associadas*, definindo-as como áreas impermeáveis, onde a cobertura original natural foi substituída por uma artificial. Por sua vez, as áreas urbanas são subdivididas em padrões lineares (ex.: malha viária) e não lineares (ex.: manchas urbanas).

A densidade das construções antrópicas pode ser descrita separadamente, conforme Di Gregório (2004), cuja subdivisão de classes é feita a partir da ocorrência de superfícies impermeáveis comparadas às superfícies permeáveis, considerando o seguinte:

- alta densidade: mais de 75% da superfície total constituída de áreas impermeáveis;
- média densidade: 50% a 75% do total da área é constituída de superfícies impermeáveis;
- baixa densidade: 30% a 50% do total da superfície são impermeáveis;
- espalhado: entre 15% e 30% da área total é constituída de superfícies impermeáveis.

Souza et al. (2003) também sugerem uma subdivisão das classes que modelam o espaço urbano, as quais estão dispostas em três níveis de detalhamento. Essa proposta constitui uma adaptação do trabalho de Herold et al. (2002) e é apresentada na Tabela 13.

Tabela 13: Classes de cobertura da terra urbana propostas por Souza et al. (2003).

| NÍVEL I               | NÍVEL II              | NÍVEL III   |
|-----------------------|-----------------------|---|
| 1 Área construída     | 1.1 Telhados          | 1.1.1 Cerâmica<br>1.1.2 Amianto / laje exposta<br>1.1.3 Metálica      |
|                       | 1.2 Pavimentação      | 1.2.1 Asfalto claro<br>1.2.2 Asfalto escuro<br>1.2.3 Sem pavimentação |
|                       | 1.3 Outras coberturas | 1.3.1 Quadra e galpão<br>1.3.2 Sombra                                 |
| 2 Vegetação           | 2.1 Densa             | 2.1.1 Mata natural  |
|                       | 2.2 Agricultura       | 2.2.1 Solo preparado<br>2.2.2 Cultura plantada                        |
|                       | 2.3 Vegetação urbana  | 2.3.1 Árvores<br>2.3.2 Jardins<br>2.3.3 Grama                         |
| 3 Área não construída | 3.1 Solo exposto      | 3.1.1 Terraplenagem   |
|                       |                       | 3.1.2 Solo sem vegetação  |
| 4 Água                | 4.1 Corpos d'água     | 4.1.1 Corpos d'água   |
|                       | 4.2 Piscinas          | 4.2.1 Piscinas  |

Fonte: SOUZA et al. (2003).

Pinho, Kux e Almeida (2007) propuseram uma hierarquia de classes para o desenvolvimento de um experimento na cidade de São José dos Campos (SP) (Figura 10). Nesse trabalho foi utilizada a classificação por regiões com abordagem *fuzzy* para a extração das informações de interesse relacionadas a cada classe.

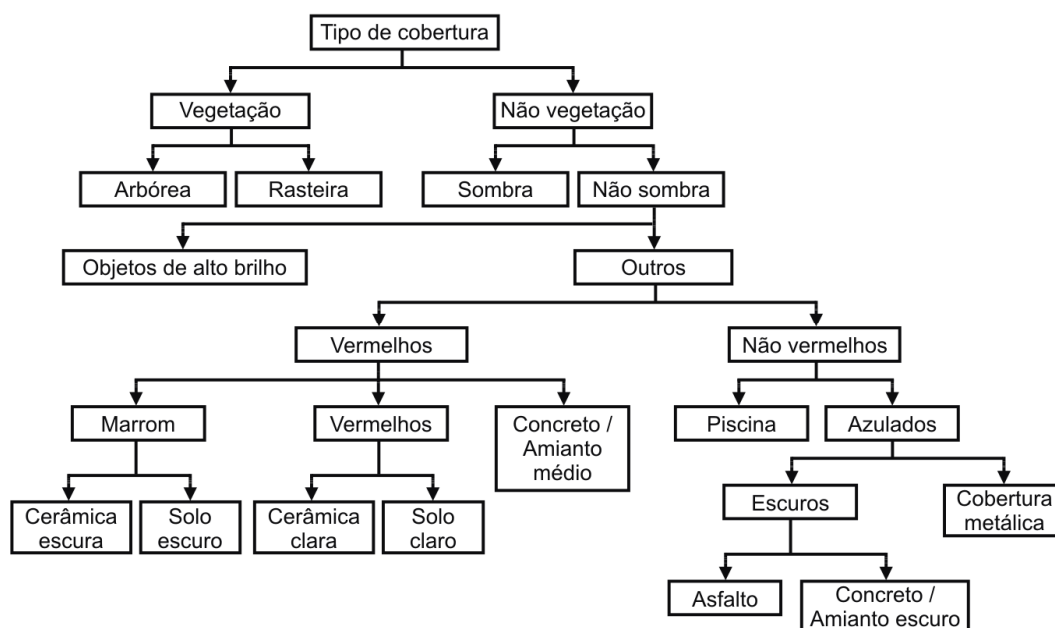


Figura 10: Hierarquia de classes para ambientes urbanos, proposta por Pinho, Kux e Almeida (2007).



Além do que já foi mencionado, também foram consultados os trabalhos publicados pelos seguintes autores: Paes, Pinto e Dutra (2003); Andrade, Botelho e Centeno (2003); Pinho e Kux (2004); Pinho, Feitosa e Kux (2005); Silva Filho et al. (2005); Lizarazo (2006); Araújo, Kux e Florenzano (2007); os quais trazem contribuições no que se refere à definição de classes para mapeamentos em escala urbana.



## 5 PROPOSTA DO SISTEMA HIERÁRQUICO DE CLASSIFICAÇÃO

Propor um sistema hierárquico de classificação não é uma tarefa trivial, visto que existe uma grande variedade de legendas, ou mesmo de sistemas de classificação com classes pouco compatíveis entre si. Ainda que a nomenclatura das classes seja similar, em alguns casos, nem sempre as definições dos critérios para as classes são únicas.

Apesar da dificuldade, ao estabelecer o sistema de classificação que será apresentado nesta pesquisa, buscou-se contribuir para a definição de um sistema padrão que possa ser utilizado como referência para aqueles que pretendem realizar mapeamentos da cobertura da terra. Esse sistema prioriza a cobertura observada no território brasileiro podendo também ser aplicado ou adaptado para outras regiões de cobertura similar.

### 5.1 Proposta do sistema hierárquico para escala regional

O sistema hierárquico de classificação para o mapeamento em escala regional foi estabelecido, principalmente, com base nos sistemas de classificação propostos por Anderson et al. (1976) e pelo Projeto CORINE *Land Cover*, bem como pelo Projeto de Uso da Terra elaborado pelo IBGE. Outros sistemas de classificação internacionais também foram consultados, dentre os quais destacam-se os elaborados por: FAO (DI GREGÓRIO, 2004); Ministério de Recursos Naturais de Ontário, Canadá (OMNR, 1999); Projeto de Uso e Cobertura da Terra do Arkansas, EUA (GORHAM, 1999); sistema de classificação do Projeto LUCAS 2006 (*Land Use/Cover Area Frame Statistical Survey* – Levantamento estatístico do quadro de área de uso e de cobertura da terra), estabelecido para países europeus (EC, 2006); e Sistema de Uso e Cobertura da Terra de Michigan, EUA (MDNR, 2001). Ainda, para definir as classes de vegetação, a principal referência considerada foi o Manual Técnico da Vegetação Brasileira, proposto por IBGE (1992b).

Este sistema hierárquico e *a priori* foi definido em três níveis de detalhamento (Tabela 14), visando mapeamentos de cobertura da terra a partir de imagens de sensoriamento remoto, principalmente, mas que também podem ser realizados usando fotografias aéreas, levantamentos de campo ou pela combinação de fontes de dados.



Tabela 14: Sistema hierárquico de classificação para o mapeamento da cobertura da terra em escala regional.

| NÍVEL I                               | NÍVEL II  | NÍVEL III                                     |
|---------------------------------------|---|---|
| 1 Superfície construída               | 1.1 Edificação urbana / rural                               | 1.1.1 Edificação urbana / rural               |
|                                       | 1.2 Malha viária / ferroviária                              | 1.2.1 Malha viária<br>1.2.2 Malha ferroviária |
| 2 Área agrossilvopastoril             | 2.1 Cultura agrícola  | 2.1.1 Cultura agrícola permanente*            |
|                                       |   | 2.1.2 Cultura agrícola temporária*            |
|                                       |   | 2.1.3 Solo preparado / Cultura recém-colhida  |
| 2.2 Pastagem                          | 2.2.1 Pastagem cultivada                                    |   |
|                                       | 2.2.2 Pastagem degradada                                    |   |
| 2.3 Reflorestamento / Florestamento   | 2.3.1 Reflorestamento / Florestamento com Pinus             |   |
|                                       | 2.3.2 Reflorestamento / Florestamento com Eucaliptos        |   |
|                                       | 2.3.3 Reflorestamento / Florestamento com outras espécies** |   |
| 3 Área úmida                          | 3.1 Área úmida continental                                  | 3.1.1 Pântano                                 |
|                                       |   | 3.1.2 Planície alagável<br>3.1.3 Palmeiral    |
| 3.2 Área úmida litorânea              | 3.2.1 Campo salino  |   |
|                                       | 3.2.2 Manguezal   |   |
|                                       | 3.2.3 Restinga  |   |
|                                       | 3.2.4 Salina  |   |
| 4 Água                                | 4.1 Água continental  | 4.1.1 Curso d'água                            |
|                                       |   | 4.1.2 Lago / Lagoa                            |
| 4.1.3 Reservatório                    |   |   |
| 4.2 Água marinha                      | 4.2.1 Baía / Estuário                                       |   |
|                                       | 4.2.2 Laguna costeira                                       |   |
|                                       | 4.2.3 Mar / Oceano  |   |
| 5 Formação vegetacional               | 5.1 Formação florestal                                      | 5.1.1 Formação florestal densa                |
|                                       |   | 5.1.2 Formação florestal aberta               |
|                                       |   | 5.1.3 Formação florestal mista                |
| 5.1.4 Formação florestal decidual     |   |   |
| 5.1.5 Formação florestal semidecidual |   |   |
| 5.2 Formação savânica                 | 5.2.1 Formação savânica arbórea                             |   |
|                                       | 5.2.2 Formação savânica arbustiva                           |   |
|                                       | 5.2.3 Formação savânica herbácea                            |   |
| 5.3 Formação campestre                | 5.3.1 Formação campestre arbustiva                          |   |
|                                       | 5.3.2 Formação campestre herbácea                           |   |
| 6 Área sem cobertura vegetal          | 6.1 Área sem cobertura vegetal                              | 6.1.1 Solo exposto                            |
|                                       |   | 6.1.2 Área degradada                          |
|                                       |   | 6.1.3 Praia / Duna / Areal                    |

\* O nome da classe pode ser mantido ou substituído pelo(s) tipo(s) de cultura(s) em questão.

\*\* O nome da classe é estabelecido em função da espécie considerada.

O nível I do sistema hierárquico proposto nesta pesquisa é semelhante ao que foi estabelecido para o Projeto CORINE *Land Cover*, o qual contempla seis categorias abrangentes de cobertura da terra. A distinção, nesse caso, é que foi acrescida uma sexta classe e também foram feitas alterações na nomenclatura adotada para as classes.



Quanto ao nível II, o mesmo foi proposto com base nos quatro principais sistemas destacados nesta pesquisa, sendo composto por treze subclasses. Pôde-se observar que, tanto o sistema do IBGE, quanto os propostos por Anderson et al. (1976) e pelo Projeto CORINE *Land Cover*, apresentaram, além de classes de cobertura da terra, categorias de uso, as quais foram desconsideradas. Por exemplo, no caso do sistema estabelecido por Anderson et al. (1976), todas as subclasses do nível II, referente à classe *Terra urbana ou construída*, são tipos de uso da terra. Para caracterizar a vegetação foram sugeridas alterações na nomenclatura proposta por IBGE (1992b) para as Regiões Fitoecológicas, reduzindo para três tipos de estruturas (*Formação florestal*, *Formação savânica* e *Formação campestre*), e foram desconsideradas as tipologias vegetacionais específicas de regiões não ocorrentes no Brasil, como, por exemplo, aquelas observadas no bioma tundra.

Por último, o nível III foi definido com trinta e sete subclasses considerando, principalmente, o sistema proposto pelo Projeto CORINE *Land Cover*, e também foi consultado o Manual Técnico da Vegetação Brasileira. Contudo, para descrever as subclasses de *Formação vegetacional*, optou-se por não utilizar todas as subdivisões das Regiões Fitoecológicas apresentadas no referido Manual, conforme mostrado na Tabela 12. Nesse sentido, deve-se destacar o seguinte:

- para as subclasses de *Formação florestal* optou-se por manter a nomenclatura recomendada por IBGE (1992b), sendo esta: *Formação florestal densa*, *Formação florestal aberta*, *Formação florestal mista*, *Formação florestal decidual* e *Formação florestal semidecidual*. Cada uma dessas subclasses pode ser observada em regiões específicas do país e, assim, deve-se conhecer, previamente, a área a ser mapeada, a fim saber qual o tipo (ou tipos) de formação florestal a ser considerado;
- para as subclasses de *Formação savânica* propõe-se, nesta pesquisa, a caracterização fitofisionômica baseada no porte da vegetação, isto é, baseada em três estratos<sup>9</sup> distintos: arbóreo, arbustivo e herbáceo. Acredita-se que essa é uma alternativa para facilitar a estratificação das formações savânicas em relação ao que propõe IBGE (1992b);
- para as subclasses de *Formação campestre* propõe-se, novamente, a caracterização por estratos, mas considerando apenas dois: arbustivo e herbáceo, visto que esse tipo de formação é caracterizado pela não ocorrência de árvores. Para os casos em

<sup>9</sup> Conforme IBGE (1992), os estratos referem-se às situações verticais como se dispõem as plantas dentro de uma comunidade vegetal, avaliadas em metros.



que há mistura de árvores, arbustos e herbáceas, a formação deixa de ser campestre e passa a ser savânica. Conforme a região a ser mapeada, sabe-se o tipo de formação vegetal que se espera encontrar, seja florestal, savânica ou campestre.

Observa-se, no sistema proposto nesta pesquisa, que o nível I está relacionado com uma escala global (exploratória) e os níveis II e III constituem a escala regional propriamente dita, de reconhecimento e semi-detahle, respectivamente. Trata-se de um sistema amplo, com um grande conjunto de classes, que pode suprir a necessidade de uma variedade de usuários, e que é aplicável a diferentes escalas e em diferentes níveis de detalhamento. Dessa forma, o sistema proposto abrange níveis mais generalizados e de menor detalhamento, a partir dos quais, cada usuário pode detalhar os níveis IV e V de forma a atender as suas necessidades específicas de mapeamento. Outra alternativa, caso seja necessário, é fazer adaptações das classes propostas nos níveis II e III do sistema para adequar algumas dessas categorias a fins muito específicos de determinados usuários, ou mesmo introduzir novas classes que não tenham sido contempladas pelo sistema.

Conforme o que se observa nos diferentes sistemas de classificação existentes na literatura, tanto nos sistemas de vegetação, quanto naqueles voltados à identificação de alvos específicos, ou, ainda, os mais abrangentes, como os propostos por Anderson et al. (1976) e pelo Projeto CORINE *Land Cover*, costumam, em geral, estar associados a escalas de mapeamento e/ou ao tipo de dado recomendado para a extração das informações de interesse. No caso de uma abordagem hierárquica, normalmente, para cada nível de detalhamento indica-se uma escala específica e destaca-se o intervalo de resolução espacial adequado para representar os dados, quando se trata de um sistema voltado para o mapeamento a partir de imagens de sensoriamento remoto.

Contudo, visto que os tipos de mapeamento podem variar, em função dos objetivos da análise e das características da área de estudo, é difícil restringir a escala de mapeamento e a resolução espacial dos dados necessários à extração da informação para cada nível de detalhamento. Não existe um consenso, nem mesmo entre pesquisadores do tema, no sentido de padronizar as recomendações. Em relação ao sistema proposto por Anderson et al. (1976), por exemplo, pode-se considerar o que é apresentado por Aronoff (2005), listado na Tabela 7, ou o que é descrito por Jensen (1996), sobre as características dos dados e as escalas adequadas.

A escolha da resolução espacial mais adequada dependerá, então, dos objetivos pretendidos, ou seja, do nível de detalhamento que se quer considerar para o



mapeamento da cobertura da terra. Além disso, as características inerentes à cena é outro fator que deve ser analisado, visto que cada área a ser mapeada apresenta padrões específicos de variabilidade dos alvos, que podem tornar mais ou menos complexo o processo de extração de informação. Dessa forma, com o aumento do nível de detalhamento e da complexidade da cena, torna-se necessário recorrer a dados com melhor resolução espacial.

Por outro lado, Markhan e Townshend<sup>10</sup> (1981, apud CAO e LAM 1997) afirmam que a resolução espacial de uma imagem também pode dificultar a sua classificação. Isso ocorre porque uma melhor resolução espacial aumenta a variação espectral dos tipos de cobertura e variações dentro de uma mesma classe, conseqüentemente, aumentam a sobreposição das classes no espaço multiespectral, resultando em uma classificação com menor acurácia. Logo, é recomendável utilizar imagens com resolução espacial suficiente para suprir a necessidade do analista.

Além disso, é importante ressaltar que, muitas vezes, a separação de determinados tipos de cobertura depende, principalmente, de uma melhor resolução espectral do que espacial. Um sensor que possui uma resolução espectral melhorada, isto é, que dispõe de um maior número de bandas situadas em diferentes regiões espectrais pode facilitar a discriminação de alvos.

Diante disso, fica claro que não existe uma regra para a seleção das características de dados orbitais, mas recomendações podem ser feitas com base no que propõe diferentes autores, bem como no conhecimento prático advindo da realização de mapeamentos temáticos. Essas recomendações servem como uma orientação, devendo, cada analista, decidir pelo tipo de dado que melhor se adequa a cada projeto de classificação. Assim, pode-se dizer que:

- considerando o nível I do sistema em escala regional, proposto nesta pesquisa, imagens com resolução espacial em torno de 80 m (ex.: MSS/Landsat) são suficientes. Outra alternativa é o uso de imagens TM/Landsat-5 de 30 m, ou CCD/CBERS (CBERS-2 ou CBERS-2B) de 20 m;
- para o nível II, imagens TM/Landsat-5 ou CCD/CBERS são satisfatórias; e
- para o nível III, novamente pode-se considerar imagens TM/Landsat-5 ou CCD/CBERS, ou ainda imagens pancromáticas HRS/SPOT-5 de 10 m e multiespectrais HRG/SPOT-5 de 5 m.

---

<sup>10</sup> MARKHAM, B. L.; TOWNSHEND, J. R. G. Land cover classification accuracy as a function of sensor spatial resolution. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF THE ENVIRONMENT, 15., Ann Arbor, Michigan. **Proceedings...** Ann Arbor: ISPRS, 1981. p. 384-392.



Além da resolução, como mencionado, os diferentes sistemas de classificação costumam ser relacionados a escalas de mapeamento, ou seja, para cada nível de detalhamento de um sistema é sugerida uma escala para a representação cartográfica da área mapeada. Contudo, classes de cobertura propostas em um determinado nível hierárquico podem ser utilizadas para mapear diferentes regiões territoriais, de modo que a melhor escala de mapeamento é aquela que melhor se adequa à extensão da área de estudo.

IBGE (1999b) destaca que os produtos cartográficos de natureza temática incluem cartas e mapas e podem ser representados em qualquer escala. Segundo Oliveira (1993), as cartas são representações em escala grande, geralmente em 1:500, 1:1.000, 1:2.000 e 1:5.000, e os mapas costumam ser produzidos nas escalas médias de 1:25.000, 1:50.000, 1:100.000 e 1:250.000, ou pequenas, em 1:500.000 e menores.

Dessa forma, é possível tanto adequar a escala do mapeamento à área de estudo, quanto selecionar escalas normalmente utilizadas. Se esse último aspecto for considerado, recomendações podem ser feitas a cada nível de detalhamento do sistema em escala regional, tais como:

- o nível I pode ser indicado para o mapeamento em escalas entre 1:1.000.000 – 1:500.000;
- o nível II, para o mapeamento em escalas entre 1:250.000 – 1:100.000; e
- o nível III, para o mapeamento em escalas maiores que 1:100.000.

A seguir são apresentadas a nomenclatura do sistema hierárquico em escala regional e as descrições dos critérios para as classes, isto é, os critérios utilizados para defini-las.

## – Nomenclatura e descrições dos critérios para as classes

### **1 Superfície construída**

#### 1.1 Edificação urbana / rural

##### *1.1.1 Edificação urbana / rural*

Área antrópica formada por cidade e/ou vila, localizada em área urbana de município, ou formada por complexo administrativo, industrial e/ou comercial, ou ainda por edificações isoladas, que se localizam em área rural.



## 1.2 Malha viária / ferroviária

### *1.2.1 Malha viária*

Feição antrópica caracterizada por rodovias e principais avenidas.

### *1.2.2 Malha ferroviária*

Feição antrópica onde se encontram linhas de transporte ferroviário.

## **2 Área agrossilvopastoril**

### 2.1 Cultura agrícola

#### *2.1.1 Cultura agrícola permanente*

Área agrícola não sujeita ao replantio após a colheita, uma vez que propicia mais de uma colheita ou produção, bem como apresenta prazo de vida útil superior a um ano, incluindo plantação de laranja, algodão, café, banana, maçã etc. (BRASIL, 2001).

#### *2.1.2 Cultura agrícola temporária*

Área agrícola sujeita ao replantio após a colheita, possuindo um período de vida muito curto entre o plantio e a colheita, incluindo cultivo de feijão, legumes, arroz, trigo etc. (BRASIL, 2001).

#### *2.1.3 Solo preparado / Cultura recém-colhida*

Área cujo solo está preparado para o plantio de cultura permanente e/ou temporária, ou área onde foi realizada a colheita recente.

### 2.2 Pastagem

#### *2.2.1 Pastagem cultivada*

Área utilizada extensivamente para pecuária, onde se encontram estruturas agrícolas, tais como abrigos, cercas, comedouros e bebedouros. Inclui tanto área de pastagem natural quanto plantada.

#### *2.2.2 Pastagem degradada*

Área de pastagem que sofreu um processo gradativo da perda de vigor, da produtividade, do valor nutritivo e da capacidade de recuperação natural da planta forrageira para sustentar os níveis de produção e qualidade exigida pelos animais, mesmo durante o período das águas, assim como a capacidade de superar os efeitos nocivos de pragas, doenças e invasoras, culminando com a degradação avançada dos recursos naturais, em razão de manejos inadequados (MOURA et al., 2007).





## 2.3 Reflorestamento / Florestamento

Reflorestamento: é a ação do homem de recompor a cobertura arbórea através do replantio com espécies nativas<sup>11</sup>, exóticas<sup>12</sup> ou heterogêneas, em áreas anteriormente florestadas (ART, 1998; ACIESP, 1997).

Florestamento: é a ação de conversão de terras que não tinham sido florestadas por um período de, no mínimo, 50 anos para terras florestadas por plantação, semeadura e/ou ação humana promovendo semeadura natural (SCARPINELLA, 2002).

Conforme Scarpinella (2002), as florestas plantadas no Brasil são, predominantemente, formadas pelos gêneros *Pinus* e *Eucalyptus*, sendo estas as duas espécies destacadas nesta pesquisa. Contudo, essa prática também é desenvolvida com outras espécies, tais como: Acácias, Araucárias, Algarobas, Palmeiras, Frutíferas, dentre outras.

### *2.4.1 Reflorestamento / Florestamento com Pinus*

Área de silvicultura na qual foi feito o reflorestamento ou o florestamento com o plantio de *Pinus*.

### *2.4.2 Reflorestamento / Florestamento com Eucaliptos*

Área de silvicultura na qual foi feito o reflorestamento ou o florestamento com o plantio de Eucalipto.

### *2.4.3 Reflorestamento / Florestamento com outras espécies*

Área de silvicultura na qual foi feito o reflorestamento ou o florestamento com o plantio de outras espécies, além de *Pinus* e Eucaliptos, incluindo o plantio com espécies mistas.

## **3 Área úmida**

### 3.1 Área úmida continental

#### *3.1.1 Pântano*

Área úmida continental inundada o ano inteiro, ou com água próxima da superfície do solo, que tem baixa drenagem. Inclui área com abundante vegetação arbóreo-arbustiva ou subarbustiva.

---

<sup>11</sup> Espécies nativas são aquelas de ocorrência natural na região mapeada, sem que tenham sido introduzidas pelo homem (SCARPINELLA, 2002).

<sup>12</sup> Espécies exóticas consistem naquelas que foram estabelecidas pela primeira vez em um local situado à distâncias significativas de sua região de ocorrência natural (SCARPINELLA, 2002).



### 3.1.2 Planície alagável

Área úmida alagada ou sujeita a alagamento por água doce, durante os períodos das cheias dos rios, córregos e ribeirões, ou as depressões alagáveis todos os anos.

### 3.1.3 Palmeiral

Área úmida, em solo bem ou mal drenado, caracterizada pela presença marcante de uma única espécie arbórea de Palmeira, tal como: Buritizal, Açaizal, Babaçual, dentre outro palmeiral.

## 3.2 Área úmida litorânea

### 3.2.1 Campo salino

Área alagada ou sujeita a alagamento por água salgada, durante a maré-alta, em algum momento do ciclo anual de marés, ou área alagada permanentemente, com vegetação que ocupe zonas de salinidade e umidade variáveis, em geral com a presença de vegetação herbácea.

### 3.2.2 Manguezal

Ecossistema litorâneo que ocorre em terrenos baixos, sujeitos à ação das marés, formados por vasas lodosas recentes ou arenosas, às quais se associa, predominantemente, a vegetação natural conhecida como mangue, com influência flúvio-marinha, típica de solos limosos de regiões estuarinas e com dispersão descontínua ao longo da costa brasileira, entre os Estados do Amapá e Santa Catarina (CONAMA, 2002). A formação vegetal é composta por arbustos e espécies arbóreas, em geral, com altura variando entre 5 e 20 m, com predominância de troncos finos e raízes aéreas e respiratórias adaptadas a salinidade e a solos pouco oxigenados.

### 3.2.3 Restinga

Área de cobertura vegetal que ocorre paralela a linha da costa, em locais como praias, cordões arenosos, dunas e depressões. De acordo com o estágio sucessional, essa vegetação manifesta-se, em geral, nos estratos herbáceo e/ou arbustivo, mas também pode existir no estrato arbóreo, este último mais interiorizado (CONAMA, 2002).

### 3.2.4 Salina

Área de produção de sal marinho pela evaporação da água do mar ou de lago de água salgada. O sal marinho formado na salina é uma rocha sedimentar química que tem origem na precipitação da água salgada, quando esta sofre evaporação.



## 4 Água

### 4.1 Água continental

#### 4.1.1 Curso d'água

Corpo de água doce linear, que flui, com continuidade, de uma elevação mais alta para uma elevação mais baixa pela força da gravidade (ART, 1998). Inclui os rios, córregos, riachos, arroios<sup>13</sup>, ribeirões, igarapés<sup>14</sup>, canais e outros corpos d'água lineares.

#### 4.1.2 Lago / Lagoa

Corpos de água doce distintos quanto à extensão e profundidade: lagoas podem ser definidas como lagos de pequena extensão e profundidade.

Uma lagoa é uma depressão de formas variadas, principalmente tendendo a circulares, podendo ser temporária e existir apenas na estação chuvosa, transformando-se em pastos por ocasião da estação seca (GUERRA, 1993).

Um lago é formado por depressões do solo produzidas por causas diversas e cheias de águas confinadas, mais ou menos tranqüilas. As formas, as profundidades e as extensões dos lagos são muito variáveis. Geralmente são alimentados por um ou mais rios afluentes<sup>15</sup> e possuem também rios emissários<sup>16</sup>, que evitam o seu transbordamento (GUERRA, 1993).

#### 4.1.3 Reservatório

Corpo d'água artificial construído com as mais variadas finalidades, tais como: regularização de cursos d'água para o abastecimento humano e/ou produção de energia elétrica; controle de enchentes; irrigação; paisagismo; lazer; estabilização de esgotos etc.

### 4.2 Água marinha

#### 4.2.1 Baía / Estuário

Uma formação de baía consiste em porção do oceano, mar ou lago que adentra pelo continente, caracterizando-se por apresentar uma linha de costa com a concavidade voltada para o exterior. Pode ser de dois tipos: aberta, delimitada por dois pontões rochosos, com uma distância suficiente de modo a permitir que as ondas no seu

<sup>13</sup> Arroio é a denominação dada aos pequenos rios no sul do Brasil (GUERRA, 1993).

<sup>14</sup> Igarapé é a denominação dada aos pequenos rios na região amazônica (GUERRA, 1993).

<sup>15</sup> Rio afluente é o corpo d'água cujo volume ou descarga contribui para aumentar outro, no qual desemboca, sendo também denominado rio tributário (IBGE, 2004b).

<sup>16</sup> Rio emissário de um lago é o corpo d'água formado a partir de um lago (IBGE, 2004b).



interior tenham as mesmas características das observadas em mar aberto; ou fechada, se comunicando indiretamente com o mar aberto através de passagens estreitas (IBGE, 2004b).

Uma formação de estuário é um corpo de água costeira, semi-fechado, que apresenta uma conexão com o mar aberto e que é influenciado pela ação das marés. Em seu interior, a água do mar é misturada com a água doce proveniente de drenagem terrestre, produzindo um gradiente de salinidade (ACIESP, 1997), isto é, a água estuariana é uma mistura parcialmente salina de água do mar e de água doce (ART, 1998).

#### 4.2.2 Laguna costeira

Extensão de água salgada em zona costeira, separada do mar por um canal de terra, ou outra topografia similar. Esse tipo de corpo d'água pode encontrar-se ligado ao mar em determinados pontos, seja permanentemente ou apenas em alguns períodos do ano (BOSSARD; FERANEC; OTAHEL, 2000).

#### 4.2.3 Mar / Oceano

Largas extensões de água salgada existentes além da zona costeira (ou faixa litorânea), isto é, a zona de transição entre o domínio continental e o domínio marinho. O mar faz a conexão entre as zonas costeiras e os oceanos.

## 5 Formação vegetal

### 5.1 Formação florestal

As formações florestais são subdivididas em Ombrófilas e Estacionais, conforme o clima da região em estudo (IBGE, 1992b). A Floresta Ombrófila é caracterizada por apresentar, no máximo, quatro meses secos, e pode ser de três tipos: densa, aberta e mista. Por outro lado, a Floresta Estacional pode apresentar quatro a seis meses secos, ou três meses com temperatura abaixo de 15 °C, sendo subdividida em Decidual e Semidecidual. Portanto, das cinco subclasses de *Formação florestal*, três podem ser utilizadas para mapeamentos de Florestas Ombrófilas, e duas, de Florestas Estacionais.

#### 5.1.1 Formação florestal densa

Área com predominância de espécies arbóreas. O dossel uniforme é característico, mas pode apresentar também um dossel emergente e um estrato intermediário com palmeiras (IBGE, 1992b).

### 5.1.2 Formação florestal aberta

Área de floresta também com predominância de espécies arbóreas, porém, constituída principalmente por espécies de palmeiras, bambus, sororoca e cipó, que formam um dossel aberto (IBGE, 1992b).

### 5.1.3 Formação florestal mista

Área de floresta conhecida como “mata de araucária ou pinheiral”, onde predominam espécies de araucárias e de pinheiros. Algumas regiões também podem ser compostas por uma submata formada por outras espécies vegetais (IBGE, 1992b). No Brasil, há poucas espécies nativas de coníferas<sup>17</sup>, com destaque para o pinheiro-brasileiro ou pinheiro-do-paraná (*Araucaria angustifolia*); além de umas poucas espécies de podocarpo (*Podocarpus*).

### 5.1.4 Formação florestal decidual

Área de floresta caracterizada por duas estações climáticas bem demarcadas, isto é, uma época chuvosa seguida de longo período biologicamente seco, podendo apresentar mais de 50% de árvores caducifólias<sup>18</sup>, e uma curta época muito fria e que ocasiona um dossel emergente completamente caducifólio.

### 5.1.5 Formação florestal semidecidual

Vegetação condicionada pela dupla estacionalidade climática, ou seja, uma época de intensas chuvas de verão, seguida por estiagem acentuada, e outra de intenso frio do inverno, com temperaturas médias inferiores a 15 °C. A porcentagem das árvores caducifólias, no conjunto florestal, situa-se entre 20 e 50%.

## 5.2 Formação savânica

### 5.2.1 Formação savânica arbórea

Formação savânica com estrato arbóreo predominante. Além disso, pode apresentar uma submata de porte arbustivo, porém, menos significativa, e vegetação herbácea revestindo o solo.

### 5.2.2 Formação savânica arbustiva

Formação savânica com estrato arbustivo predominante, podendo apresentar um estrato herbáceo revestindo o solo.

---

<sup>17</sup> Coníferas são vegetais do grupo das gimnospermas, geralmente de grande porte. Tipicamente perenifólias, sendo raras as exceções, mostram folhas quase sempre muito finas (acículas). Exemplos de coníferas são as araucárias, os pinheiros e as sequóias (IBGE, 2004b).

<sup>18</sup> Ao contrário das plantas perenifólias, que mantêm as suas folhas durante todo o ano, as caducifólias são plantas que perdem suas folhas em certa estação do ano, geralmente nos meses mais frios e sem chuva.



### 5.2.3 Formação savânica herbácea

Formação savânica com estrato herbáceo predominante, podendo apresentar vegetação arbustiva e/ou arbórea espalhada.

## 5.3 Formação campestre

### 5.3.1 Formação campestre arbustiva

Formação campestre com presença significativa de estrato arbustivo e vegetação herbácea (gramíneas e não-gramíneas) revestindo o solo.

### 5.3.2 Formação campestre herbácea

Formação campestre com estrato herbáceo predominante, podendo apresentar vegetação arbustiva espalhada.

## 6 Área sem cobertura vegetal

### 6.1 Área sem cobertura vegetal

#### 6.1.1 Solo exposto

Área decorrente de processos geológicos naturais em diferentes tipos de rochas, ou gerados pela ação contínua do homem que interage com o ambiente de forma significativa, modificando a paisagem. Trata-se da rocha nua, exposta, sem cobertura vegetal, incluindo afloramentos rochosos naturais ou artificiais<sup>19</sup>, costões rochosos<sup>20</sup> e recifes situados acima da linha de maré alta.

#### 6.1.2 Área degradada

Área cuja cobertura vegetal existente sofreu processo de degradação natural ou antrópica. Inclui as queimadas<sup>21</sup> e os incêndios<sup>22</sup> recentes, cujo solo não conseguiu se regenerar, ou ainda está em processo de regeneração, tendo aparência de solo escuro; as cascalheiras; e os lixões.

---

<sup>19</sup> Os afloramentos rochosos artificiais incluem as perfurações feitas para poços, a exploração de minas, cortes de estradas, escavações, pedreiras etc. (GUERRA, 1993).

<sup>20</sup> Costão rochoso é o ambiente costeiro formado por rochas situado na transição entre os meios terrestre e aquático. No Brasil, pode-se encontrar costões rochosos por quase toda a costa, desde o Estado do Rio Grande do Sul até o Estado do Maranhão (HÖFLING, 2000).

<sup>21</sup> Áreas queimadas são aquelas que sofreram degradação pelo fogo decorrente de fatores ambientais como, por exemplo, elevadas temperaturas em regiões secas.

<sup>22</sup> Áreas incendiadas são regiões que sofreram degradação pelo fogo decorrente de ações antrópicas como, por exemplo, uso do fogo para a renovação de pastagens. Outro exemplo é a prática de incendiarismo, a qual consiste na ação de atear fogo propositadamente em áreas de vegetação, cuja única intenção é destruir a cobertura vegetal, constituindo, assim, em um crime ambiental.



### 6.1.3 Praia / Duna / Areal

Compreende as pequenas, médias e grandes extensões de superfície que constituem depósitos de areias acumuladas. Inclui os depósitos arenosos no entorno de grandes rios e mares, as dunas e os areais.

## 5.2 Proposta do sistema hierárquico para escala urbana

Com relação ao sistema hierárquico para a escala urbana, deve-se enfatizar que, embora os mapeamentos nessa escala sejam, geralmente, concebidos a partir das classes específicas às regiões a serem cartografadas, nada impede que o sistema proposto nesta pesquisa seja utilizado e testado em outras aplicações. Por tal motivo, uma variedade de classes é apresentada, conquanto nem todas sejam predominantes em ambientes urbanos. Ou seja, a idéia é propor um sistema amplo que possa atender às diferentes necessidades de mapeamento e que seja aplicável em diferentes áreas de estudo.

Nesse contexto, o sistema hierárquico foi proposto com o auxílio dos diversos trabalhos consultados referentes à extração de informação em grande escala. As maiores contribuições nesse sentido foram aquelas destacadas no item 4.2 e que apresentam uma hierarquia de classes em diferentes níveis de detalhamento. Esse sistema também foi definido com três níveis de detalhamento, assim como a hierarquia proposta para mapeamentos em escala regional. O nível I abrange quatro classes globais, a partir das quais são definidas dez subclasses no nível II e vinte e sete subclasses no nível III, conforme mostra a Tabela 15. Além disso, outro nível de detalhamento também pode ser incorporado ao sistema, conforme a necessidade do usuário.

As classes do sistema em escala urbana são facilmente entendidas através da própria nomenclatura, de modo que não se faz necessário descrever cada uma dessas classes. O que é importante ser dito é que as subclasses de *Material de cobertura* são propostas no sentido de mapear tanto telhados quanto pavimentos, visto que algumas classes podem estar relacionadas a ambos os casos, como cobertura de *Cerâmica* ou de *Concreto*, por exemplo. Após esse esclarecimento, algumas observações devem ser feitas para as seguintes classes:

- *1.1.1 Cerâmica*: inclui tipos de revestimento com cerâmica branca, vermelha ou outra;



- *1.1.2 Cobertura de fibrocimento*: telhas de fibrocimento são constituídas por fibras de amianto (ou asbesto) e cimento;
- *1.1.3 Concreto*: inclui coberturas com material de concreto claro e escuro, utilizado para revestir pavimentos ou edificações (laje exposta);
- *1.1.4 Cobertura metálica*: abrange diversos tipos de cobertura metálica, como: alumínio (sem pintura ou com cores claras e escuras), aço (galvanizado, termo-acústico etc.), cobre, zinco e chumbo;
- *1.1.10 Outros*: inclui outros tipos de material de cobertura, geralmente utilizados para finalidades específicas e que ocorrem com menor frequência em ambientes urbanos.

Tabela 15: Sistema hierárquico de classificação para o mapeamento da cobertura da terra em escala urbana.

| NÍVEL I                              | NÍVEL II                             | NÍVEL III  |
|--------------------------------------|--------------------------------------|--|
| 1 Área construída                    | 1.1 Material de cobertura            | 1.1.1 Cerâmica<br>1.1.2 Cobertura de fibrocimento<br>1.1.3 Concreto<br>1.1.4 Cobertura metálica<br>1.1.5 Asfalto<br>1.1.6 Cobertura de plástico<br>1.1.7 Cobertura de vidro<br>1.1.8 Paralelepípedo<br>1.1.9 Cobertura de madeira<br>1.1.10 Outros |
| 2 Área vegetada                      | 2.1 Área vegetada natural / plantada | 2.1.1 Árvore / Arbusto<br>2.1.2 Gramado  |
|                                      | 2.2 Área úmida vegetada              | 2.2.1 Área úmida vegetada  |
|                                      | 2.3 Área agrossilvopastoril          | 2.3.1 Solo preparado / Cultura recém-colhida<br>2.3.2 Cultura agrícola*<br>2.3.3 Pastagem<br>2.3.4 Reflorestamento / Florestamento**   |
| 3 Área não construída / não vegetada | 3.1 Solo exposto                     | 3.1.1 Areia<br>3.1.2 Rocha<br>3.1.3 Solo   |
|                                      | 3.2 Área úmida não vegetada          | 3.2.1 Área úmida não vegetada  |
|                                      | 3.3 Área degradada                   | 3.3.1 Área degradada   |
|                                      | 3.4 Sombra                           | 3.4.1 Sombra   |
| 4 Água                               | 4.1 Água natural / quase natural     | 4.1.1 Curso d'água<br>4.1.2 Lago / Lagoa<br>4.1.3 Mar  |
|                                      | 4.2 Água artificial                  | 4.2.1 Reservatório   |

\* O tipo de cultura agrícola existente é utilizado para representar o nome da classe.

\*\* O nome da classe é definido em função da espécie considerada.

A discussão apresentada no item 5.1 desta pesquisa, sobre a resolução adequada dos dados utilizados para extrair as informações de interesse, bem como a escala de





mapeamento indicada, também é válida para o sistema hierárquico em escala urbana. Novamente, recomendações podem ser feitas, embora não exista uma regra e cada usuário deva definir as especificações adequadas ao seu projeto de classificação. Quanto ao tipo de dado, imagens com resolução espacial maior que 5 m (ex.: IKONOS II, QuickBird II e OrbView-3) podem ser utilizadas, assim como fotografias aéreas ortorretificadas. A escala de mapeamento deve ser de 1:25.000 ou maior, conforme a necessidade da aplicação.



## 6 APLICAÇÃO DO SISTEMA HIERÁRQUICO DE CLASSIFICAÇÃO

A aplicação do sistema hierárquico de classificação foi realizada em dois níveis de detalhamento, nas escalas regional e urbana, tendo as imagens de sensoriamento remoto como as principais fontes de informação. Com o propósito de descrever tal aplicação, inicialmente foi definido um estudo de caso e feita a caracterização das áreas de estudo. Em seguida, foram especificados os projetos de classificação para as escalas regional e urbana. Em cada projeto, foi apresentada a legenda do mapeamento e as descrições das classes, especificando-se as técnicas de classificação, as características dos dados e o método de análise da confiabilidade do mapeamento mais adequados a cada aplicação. Além disso, foi descrito o material utilizado, o qual incluiu imagens orbitais de resolução espacial métrica e centimétrica, dados vetoriais e aplicativos específicos selecionados para cada projeto.

Posteriormente, foram descritos os processamentos e análises realizados para cada aplicação, dentre as possibilidades mencionadas nos projetos de classificação. Para cada escala de mapeamento, foram apresentados os pré-processamentos dos dados, as técnicas de classificação e as análises das informações temáticas produzidas. Particularmente no que se refere à escala urbana, foi apresentada uma breve discussão e adequação das classes de cobertura propostas no sistema hierárquico a classes de uso da terra.

### 6.1 Caracterização das áreas de estudo

As áreas de estudo consideradas nesta pesquisa contemplam o município de Presidente Prudente, em escala regional, e uma parte da cidade de Presidente Prudente, para o mapeamento em escala urbana. Esse município possui uma extensão territorial de 562 km<sup>2</sup> e uma população superior a 202.000 habitantes (IBGE, 2007a), e está localizado no Estado de São Paulo, entre as seguintes coordenadas geográficas: 21° 40' a 22° 15' de latitude Sul e 51° 10' a 51° 32' de longitude Oeste, conforme mostra a Figura 11.



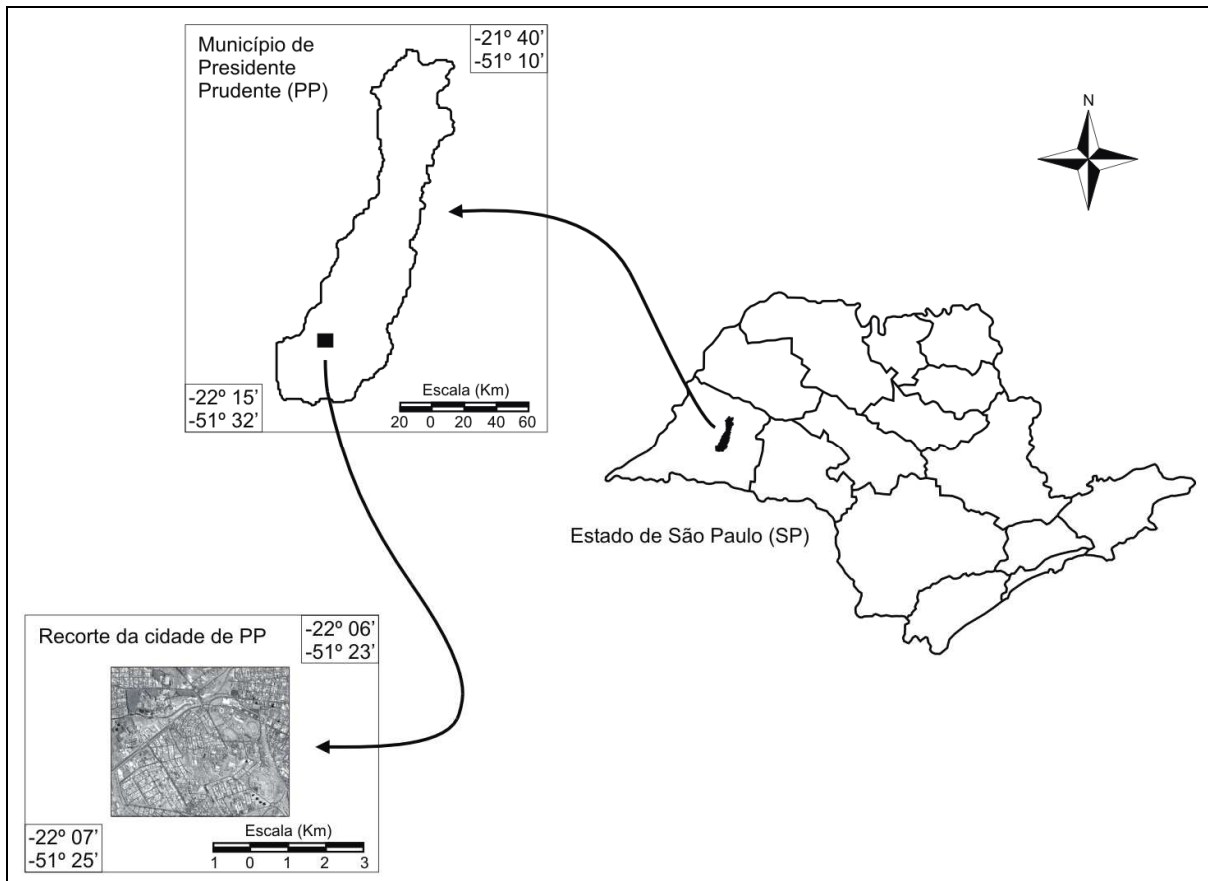


Figura 11: Localização das áreas de estudo.

De acordo com o Mapa Geomorfológico do Estado de São Paulo, elaborado na escala 1:500.000, o município de Presidente Prudente encontra-se localizado na Bacia Sedimentar do Paraná (morfoestrutura) e no Planalto Ocidental Paulista (morfoescultura), mais precisamente no Planalto Centro Ocidental (ROSS; MOROZ, 1996). No município, predominam, como formas de relevo, as colinas médias e baixas, cujas altitudes variam entre 300 a 600 m, e declividades médias entre 10% a 20% (SILVA; PERUSI; NUNES, 2005).

A região de Presidente Prudente sofre a atuação da maioria dos sistemas atmosféricos presentes na América do Sul. Pelo fato dessa região estar situada na latitude do trópico, torna-se um campo de alternância dos sistemas tropicais e polares, com dominância da massa de ar tropical marítima (AMORIM, 2000).

A história agrícola do oeste do Estado de São Paulo registra vários ciclos econômicos, desde a cultura do café até as culturas do algodão e do amendoim (PERUSI, 2001). As atividades foram desenvolvidas de forma altamente impactante, implicando num avançado quadro de degradação manifestado em diferentes graus de erosão, como ravinamentos e voçorocamentos (SILVA; PERUSI; NUNES, 2005).

A cidade de Presidente Prudente é a capital da décima região administrativa do Estado de São Paulo, constituindo um importante pólo administrativo e atrativo para os habitantes das cidades da região e vizinhas. Um planejamento adequado desse município que favoreça, cada vez mais, o seu desenvolvimento é uma forma eficaz de elevar a sua importância, e também de sua região, no cenário nacional.

## **6.2 Especificação dos projetos de classificação**

O projeto de classificação é relacionado à aplicação específica de interesse de cada usuário. No projeto devem constar informações primordiais, tais como: a legenda da classificação, isto é, a nomenclatura das classes e as respectivas descrições; os tipos de dados e as técnicas de extração de informação mais adequadas; e o método de análise da qualidade temática da informação representada.

Nesta pesquisa são consideradas duas aplicações distintas, em escalas regional e urbana, sendo que, para cada aplicação, deve haver um projeto de classificação específico. Isso é necessário, visto que, como o tipo de informação que se quer extrair é diferente, os dados e as técnicas de classificação adequadas, além dos métodos de análise da qualidade temática podem (ou devem) ser distintos.

### **6.2.1 Projeto para mapeamento em escala regional**

Na aplicação do sistema hierárquico para o mapeamento em escala regional, foi considerado, como área de estudo, todo o município de Presidente Prudente. A partir disso, conhecendo claramente qual a extensão da região de estudo, foram identificadas as classes de informação de interesse a serem mapeadas. Para tanto, foi definido, previamente, o nível de detalhamento do mapeamento que se pretendia obter, priorizando, nesse caso, a extração das informações descritas no nível II do sistema hierárquico em escala regional.

Com isso, pôde-se identificar quais classes do nível II do sistema regional deveriam estar presentes no mapeamento da área de estudo. Essas classes especificaram a legenda da classificação e suas respectivas descrições. Do total de treze subclasses listadas no



nível II (Tabela 14), oito puderam ser identificadas no município de Presidente Prudente, sendo estas:

- 1.1 *Edificação urbana / rural*: mancha urbana da cidade de Presidente Prudente e distritos;
- 1.2 *Malha viária*<sup>23</sup>: vias de transporte rodoviário;
- 2.1 *Cultura agrícola*: área de cultivos permanente e temporário e área com solo preparado para o plantio ou com colheita recente;
- 2.2 *Pastagem*: área de pastagem cultivada utilizada pelo gado;
- 3.1 *Área úmida continental*: área úmida no entorno dos cursos d'água;
- 4.1 *Água continental*: curso d'água e corpos d'água naturais e artificiais;
- 5.1 *Formação florestal*: área de vegetação arbórea que compõe a Floresta Estacional Semidecidual remanescente;
- 6.1 *Área sem cobertura vegetal*: local com afloramento rochoso ou área degradada como, por exemplo, o lixão da cidade de Presidente Prudente.

Conhecendo-se as classes temáticas de interesse ao mapeamento da região de estudo, deve-se especificar os tipos de dados necessários à extração dessa informação. Conforme mencionado, o sistema hierárquico de classificação, proposto nesta pesquisa, visa, primeiramente, a realização de mapeamentos temáticos utilizando dados de sensoriamento remoto. Assim, acredita-se que as imagens TM/Landsat-5 ou CCD/CBERS-2 (ou 2B), com 30 e 20 m de resolução espacial, respectivamente, são satisfatórias para a finalidade em questão. Essas imagens vêm sendo, constantemente, utilizadas em mapeamentos da cobertura da terra em escala regional.

Dentre as técnicas de classificação existentes, abordagens convencionais por *pixel* e por regiões são normalmente utilizadas para a obtenção das informações que se pretende mapear. Contudo, essas técnicas não permitem lidar com misturas entre tipos de cobertura, que ocorrem freqüentemente em mapeamentos em escala regional. Nesse sentido, outras técnicas menos usuais têm se mostrado mais satisfatórias, tais como as baseadas em abordagem *fuzzy*, que permitem lidar com a ocorrência de *pixels* mistos e com classes de cobertura que não apresentam limites bem definidos entre si.

A partir disso, uma forma de analisar a qualidade temática da imagem classificada é através das medidas de incerteza fornecidas pelo classificador *fuzzy* durante o processo de mapeamento. Outra possibilidade é a realização da análise da acurácia temática

---

<sup>23</sup> Na área de estudo considerada, apenas a malha viária pode ser observada nessa escala. Por esse motivo, parte da nomenclatura foi suprimida, a qual se refere à representação de malha ferroviária.



estimada pelos coeficientes estatísticos, o que se trata de um procedimento convencionalmente adotado.

## 6.2.2 Projeto para mapeamento em escala urbana

Em se tratando da aplicação do sistema de classificação em escala urbana, a região de estudo considerada foi uma parte da cidade de Presidente Prudente. Nesse caso, atingiu-se o nível de detalhamento que permitiu mapear o tipo de material de revestimento das feições, ou seja, foi considerado o nível III de detalhamento do sistema em escala urbana.

Após a definição do nível de detalhamento, identificaram-se treze subclasses de interesse ao mapeamento da área de estudo, de um total de vinte e sete subclasses, as quais foram:

- *1.1.1 Cerâmica*: cobertura de edificação ou pavimento constituída de cerâmica de diversas cores;
- *1.1.2 Cobertura de fibrocimento*: revestimento de edificação constituída de fibrocimento;
- *1.1.3 Concreto*: cobertura de edificação constituída de concreto (laje exposta), pavimentos de concreto e quadras esportivas;
- *1.1.4 Cobertura metálica*: revestimento metálico de edificação constituído por material de alumínio, aço ou cobre;
- *1.1.5 Asfalto*: revestimento asfáltico da maior parte das vias;
- *1.1.10 Outros*: revestimento de borracha utilizado na pista de atletismo da Faculdade de Ciências e Tecnologia – FCT/UNESP;
- *2.1.1 Árvore / Arbusto*: área vegetada onde ocorrem aglomerados de árvores, ou árvores e arbustos isolados;
- *2.1.2 Gramado*: área vegetada constituída por cobertura gramínea;
- *3.1.3 Solo*: área exposta constituída por solo;
- *3.3.1 Sombra*: área sombreada no entorno de árvores e edificações;
- *4.1.1 Curso d'água*: corpo de água doce linear e natural formado pelo Córrego do Veado<sup>24</sup>;

---

<sup>24</sup> O Córrego do Veado é um dos principais cursos d'água que cortam a cidade de Presidente Prudente, sendo que muitos outros passaram por processo de canalização fechada.



- 4.1.2 Lagoa<sup>25</sup>: corpo de água doce existente no campus da FCT/UNESP;
- 4.2.1 Reservatório: corpo d'água artificial destinado para o tratamento de água e de efluentes e para o lazer.

Para a extração desse tipo de informação, por meio de dados de sensoriamento remoto, deve-se utilizar imagens com resolução espacial métrica e/ou centimétrica, tais como: IKONOS (4 m de resolução no modo multiespectral e 1 m no pancromático) e QuickBird II (2,44 m no multiespectral e 0,61 m no pancromático). Apesar das vantagens decorrentes do uso dessas imagens, as quais permitem gerar mapeamentos mais detalhados, sabe-se que a paisagem urbana apresenta uma composição complexa e diversa e muitos materiais desse ambiente possuem comportamentos espectrais similares. Com isso, as técnicas convencionais de classificação, que fazem uso, normalmente, apenas de informação espectral, tornam-se limitadas. Portanto, é necessário recorrer a técnicas alternativas de classificação, como a abordagem orientada a objeto ou por rede neural artificial.

A análise da qualidade temática da classificação pode considerar tanto os coeficientes estatísticos que estimam a acurácia, quanto as medidas de incerteza, caso a técnica de classificação selecionada forneça as probabilidades dos *pixels* pertencerem a cada classe.

### 6.3 Material utilizado

Como visto, no desenvolvimento desta pesquisa foram necessárias imagens de resolução espacial métrica e centimétrica. Para a aplicação do sistema de classificação em escala regional, optou-se por utilizar uma imagem TM/Landsat-5. Essa imagem foi tomada em setembro de 2007, referente à órbita/ponto 222/75. O critério de seleção dessa imagem, especificamente, foi a ausência de cobertura de nuvens sobre a área de estudo, bem como a verificação de que as variações na cobertura terrestre se mostraram bem evidentes, visto que a aquisição foi realizada em período de menor pluviosidade em relação a outras imagens disponíveis e sem cobertura de nuvens. A utilização da imagem TM se deveu ao fato de que as imagens CCD mais atuais, dos satélites CBERS-2 e CBERS-2B, apresentam variações tonais acentuadas indicando a existência de distorções radiométricas nas cenas, as quais

---

<sup>25</sup> O corpo d'água natural existente na área de estudo possui, aproximadamente, 1190 m<sup>2</sup>, sendo considerado uma lagoa.



interferem de forma significativa no processo de classificação temática. Além disso, as imagens TM dispõem de bandas adquiridas no infravermelho médio, aumentando consideravelmente a discriminação dos alvos de interesse. A Figura 12 mostra a delimitação do município de Presidente Prudente sobre a imagem TM/Landsat-5, a qual foi obtida diretamente a partir do *site* do Instituto Nacional de Pesquisas Espaciais (INPE, 2008), que mantém um acervo digital de imagens que podem ser adquiridas gratuitamente por qualquer usuário, mediante cadastro.



Figura 12: Delimitação do município de Presidente Prudente sobre a imagem TM/Landsat-5.  
Fonte: INPE (2008).

Para a aplicação do sistema de classificação em escala urbana foram selecionadas duas imagens do satélite QuickBird II, com resoluções espaciais métrica (imagem multiespectral) e centimétrica (imagem pancromática), tomadas em fevereiro de 2007, as quais contemplam parte da área urbana de Presidente Prudente. Essas imagens estão no nível de correção padrão (*Standard Imagery*) e foram adquiridas e disponibilizadas pelo Prof. Dr. Amilton Amorim, docente do Departamento de Cartografia da FCT/UNESP, por meio de projeto de pesquisa financiado pela FAPESP. Na Figura 13 é mostrado o recorte da imagem multiespectral em composição colorida B1G2R3, na qual é associada a cor azul (B – *blue*) à banda 1, a cor verde (G – *green*) à banda 2 e a cor vermelha (R – *red*) à banda 3.





Figura 13: Composição colorida BIG2R3 da imagem multispectral QuickBird II.

Além das imagens orbitais foi adquirido um arquivo digital contendo a base do município de Presidente Prudente, georreferenciada com sistema de projeção UTM (Universal Transversa de Mercator) e *datum* SAD-69, cedida pelo Prof. Dr. João Osvaldo Rodrigues Nunes, docente do Departamento de Geografia da FCT/UNESP. Essa base está no formato vetorial e foi elaborada pela Prefeitura de Presidente Prudente, entre os anos de 1996 e 1997, a partir da restituição de fotografias aéreas datadas de 1995, na escala de 1:25.000. A finalidade da seleção dessa base vetorial foi dispor de uma informação georreferenciada para ser utilizada como referência no processo de correção geométrica das imagens orbitais.

O material utilizado nesta pesquisa também incluiu quatro aplicativos: SPRING, IDRISI, ENVI e o pacote estatístico R. Cada um desses aplicativos foi utilizado para uma finalidade específica, necessária para o desenvolvimento da metodologia de trabalho.

No SPRING, foi realizado o georreferenciamento das imagens orbitais e foi criado um Banco de Dados, no qual, após o término dos processamentos, optou-se por armazenar todos os arquivos matriciais resultantes do projeto. O SPRING (Sistema de Processamento de Informações Georreferenciadas) é um aplicativo de Sistema de Informações Geográficas (SIG) com funções de processamento de imagens e de dados vetoriais, modelagem numérica de terreno e análise espacial. Trata-se de um projeto do INPE/DPI (Divisão de Processamento de Imagens) com a colaboração das seguintes entidades: EMBRAPA/CNPTIA (Centro Nacional de Pesquisa Tecnológica em Informática

para Agricultura); IBM Brasil (Centro Latino-Americano de Soluções para Ensino Superior e Pesquisa); TECGRAF (Grupo de Tecnologia em Computação Gráfica da PUC-Rio); PETROBRÁS/CENPES (Centro de Pesquisas "Leopoldo Miguez") (INPE, 2007b). Esse aplicativo é constituído de quatro módulos: (i) IMPIMA, utilizado para realizar a conversão de formatos; (ii) SPRING, módulo principal que executa a maior parte dos processamentos; (iii) SCARTA, utilizado para edição e geração de arquivos para impressão; e (iv) IPLOT, útil para a plotagem dos arquivos elaborados com o módulo SCARTA.

O aplicativo IDRISI, selecionado para a execução das técnicas de classificação das imagens orbitais, é um SIG projetado para o processamento de imagens que foi desenvolvido pela Escola Graduada de Geografia (*Graduate School of Geography*) da *Clark University*, Estados Unidos, desde 1987. Consiste de um programa principal de interface e mais de 200 módulos para visualização, processamento e análise de dados geográficos, abrangendo um amplo espectro de necessidades de SIG e de Sensoriamento Remoto (EASTMAN, 2006).

O aplicativo ENVI (*Environment for Visualizing Images*) foi desenvolvido pela empresa RSI (*Research Systems Inc.*) e é um sistema para visualização, processamento, análise e apresentação de imagens. Esse aplicativo possui várias ferramentas para análise e extração de dados de Sensoriamento Remoto, trabalhando com análise espectral, imagens georreferenciadas, imagens de radar e superfícies 3D. Possui suporte para imagens de várias fontes e ferramenta SIG para manipulação de dados vetorial e raster (RSI, 2007). Esse sistema foi utilizado para realizar a fusão das imagens QuickBird II e para gerar imagem de textura.

Finalmente, o aplicativo R foi selecionado para o cálculo do valor da estatística qui-quadrado, durante o processo de análise da acurácia temática da classificação. Esse aplicativo consiste em um pacote estatístico que vem sendo desenvolvido, desde 1997, pelo Departamento de Estatística da Universidade de Auckland na Nova Zelândia e pode ser obtido gratuitamente a partir do *site*: <http://brieger.esalq.usp.br/CRAN/>.

#### **6.4 Processamentos e análises do mapeamento em escala regional**

Os processamentos realizados para o mapeamento em escala regional incluíram uma etapa inicial de pré-processamento, com a realização de correção geométrica e realce radiométrico, e a etapa posterior de extração e representação da informação de interesse



a partir da classificação *fuzzy* da imagem TM/Landsat-5. Em seguida, foram realizados processos de pós-classificação e a análise da qualidade temática da informação mapeada.

#### 6.4.1 Pré-processamentos dos dados

A etapa de pré-processamento consistiu, inicialmente, no georreferenciamento da imagem TM/Landsat-5 utilizando o aplicativo SPRING. As bandas TM foram convertidas do formato TIFF (*Tagged Image File Format*) para o formato GRIB através do módulo IMPIMA. Nessa etapa também foi feito o recorte das bandas, mantendo somente a região da imagem necessária para abranger a área de estudo, a fim de facilitar os processamentos posteriores. Das sete bandas adquiridas pelo sensor TM, a banda termal foi descartada nesta pesquisa, por apresentar resolução espacial inferior às demais.

No aplicativo SPRING, foi criado um Banco de Dados e definido um Projeto considerando o sistema UTM/SAD-69, o mesmo adotado para a base vetorial do município de Presidente Prudente que serviu como informação de referência. As coordenadas do retângulo envolvente do Projeto, que abrangeu integralmente a área de estudo, foram as seguintes:  $X_1 = 447.944,818$  m;  $Y_1 = 7.542.217,323$  m;  $X_2 = 480.438,585$  m;  $Y_2 = 7.600.376,028$  m.

Para a correção geométrica das bandas espectrais TM foram utilizados pontos de controle coletados na base vetorial, sendo feito o georreferenciamento modo teclado usando função de transformação linear e interpolação do valor de brilho pelo método do vizinho mais próximo. Foram considerados 20 pontos de controle identificados na base vetorial e na imagem TM e a precisão do georreferenciamento foi de 0,55 *pixel* (ou 16,5 metros).

Concluído o georreferenciamento, o limite vetorial do município de Presidente Prudente, disponibilizado pela Cooperativa de Serviços, Pesquisas Tecnológicas e Industriais – CPTI (CPTI, 1999), foi importado para o Banco de Dados. Com isso foi possível verificar, visualmente, o resultado da sobreposição do limite municipal às bandas corrigidas, conforme mostrado na Figura 14, considerando uma composição colorida B3G4R5 das bandas TM realçadas.






Figura 14: Composição colorida B3G4R5 da imagem TM/Landsat-5 e sobreposição do limite vetorial municipal.

Em seguida, as bandas TM foram convertidas para o formato GeoTIFF (TIFF Georreferenciado), a fim de que pudessem ser manipuladas em outros aplicativos, além do SPRING.

#### 6.4.2 Extração e representação da informação temática

Diante do que foi exposto nos capítulos iniciais desta pesquisa e mencionado na especificação do projeto de classificação em escala regional, técnicas de classificação convencionais nem sempre são satisfatórias, principalmente em mapeamentos nas escalas global e regional, devido à maior ocorrência de *pixels* mistos nas imagens e limites imprecisos entre determinadas classes.

Dessa forma, para classificar a imagem TM/Landsat-5, foi selecionada a técnica de classificação baseada em abordagem *fuzzy*, conhecida como classificação relativa

bayesiana. Essa técnica está implementada no aplicativo IDRISI e consiste nas etapas ilustradas no fluxograma apresentado na Figura 15.

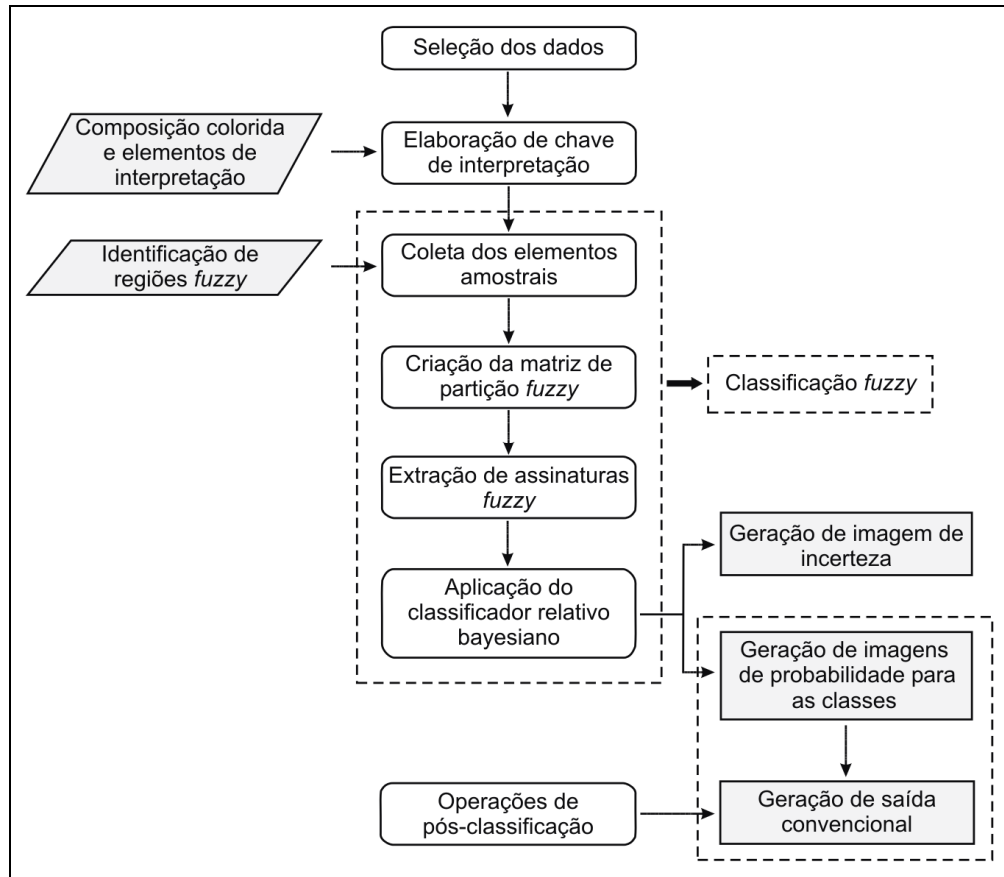
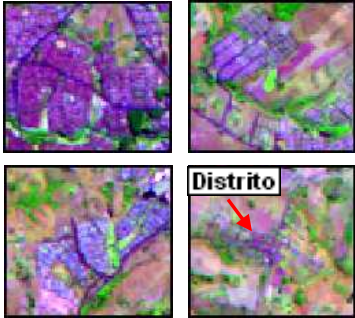
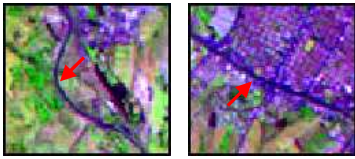

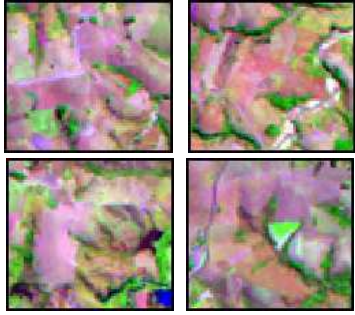
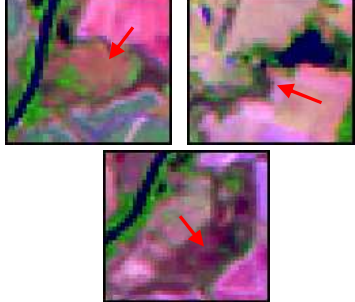


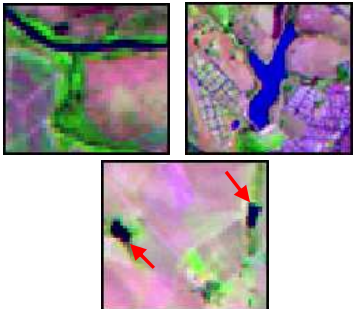
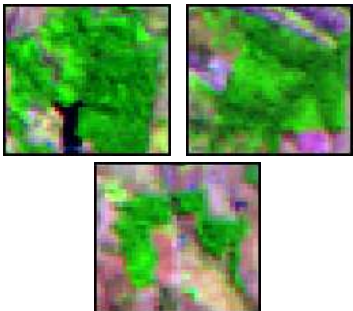
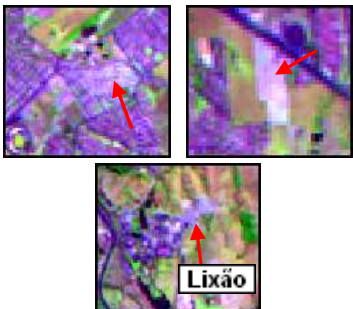
Figura 15: Fluxograma das etapas necessárias à classificação relativa bayesiana.

A primeira etapa da classificação envolveu a elaboração de uma chave de interpretação, a fim de caracterizar os alvos presentes na cena. Para tanto foi selecionada uma coleção de imagens ilustrativas dos alvos de interesse e feita a descrição das características de identificação desses alvos na imagem. Essa chave de interpretação foi gerada considerando a composição colorida B3G4R5 das bandas TM realçadas e os demais elementos de interpretação de imagem (forma, textura, padrão, localização etc.), conforme observado na Tabela 16.



Tabela 16: Chave de interpretação dos alvos da imagem TM/Landsat-5.

| ID | Classes                   | Amostras na imagem  | Descrições  |
|----|---------------------------|---|---|
| 1  | Edificação urbana / rural |    | <ul style="list-style-type: none"> <li>✓ A mancha urbana de Presidente Prudente está localizada na região sul do município e os distritos, em sentido norte;</li> <li>✓ Apresenta forma irregular e textura rugosa;</li> <li>✓ A cor varia do roxo ao lilás, sendo mais escura nas áreas de maior densidade (região central da cidade e áreas residenciais de baixo padrão) e mais clara nas regiões de menor densidade de construção (áreas de expansão urbana, com novos conjuntos habitacionais, alguns de alto padrão).</li> </ul>  |
| 2  | Malha viária              |    | <ul style="list-style-type: none"> <li>✓ Apresenta forma linear, textura lisa e cor escura, tendendo ao preto;</li> <li>✓ A ocorrência de edificações, geralmente, está associada à existência de ao menos uma via que ofereça acesso até o local.</li> </ul>   |
| 3  | Cultura agrícola          |   | <ul style="list-style-type: none"> <li>✓ No caso de cultura recém-plantada ou mais jovem, apresenta forma regular, textura lisa e tons de cor verde claro;</li> <li>✓ Quando se trata de cultura mais antiga ou próxima da colheita, mantém forma regular, com textura mais rugosa e cor variando em tons de verde escuro;</li> <li>✓ Ao se tratar de área com solo preparado ou com cultura recém-colhida, apresenta forma regular, textura lisa e cor variável, podendo ser branca, rosa, lilás ou em diferentes tons de roxo, conforme o tipo de solo e o teor de umidade;</li> <li>✓ Uma área extensa de cultura agrícola no município de Presidente Prudente está associada, em geral, à cultura de cana-de-açúcar.</li> </ul> |
| 4  | Pastagem                  |  | <ul style="list-style-type: none"> <li>✓ Apresenta forma bastante irregular, com textura geralmente lisa e cores variadas, desde áreas avermelhadas, arroxeadas e amareladas.</li> </ul>  |
| 5  | Área úmida continental    |  | <ul style="list-style-type: none"> <li>✓ Está localizada no entorno de corpos d'água e cursos d'água;</li> <li>✓ Apresenta forma irregular, com textura geralmente lisa e cores tendendo ao marrom escuro.</li> </ul>   |

|   |                            |  |   |
|---|----------------------------|--|---|
| 6 | Água continental           |   | <ul style="list-style-type: none"> <li>✓ Apresenta forma irregular e textura lisa;</li> <li>✓ A cor varia do azul escuro tendendo ao preto, na existência de baixa quantidade de sedimentos em suspensão; ou em tons de azul claro, para corpos d'água com maior quantidade de sedimentos em suspensão.</li> </ul>  |
| 7 | Formação florestal         |   | <ul style="list-style-type: none"> <li>✓ Apresenta forma irregular, textura rugosa e cor verde escura;</li> <li>✓ Geralmente, está localizada no entorno ou próxima a corpos d'água, pois trata-se de vegetação remanescente da Floresta Estacional Semidecidual.</li> </ul>  |
| 8 | Área sem cobertura vegetal |  | <ul style="list-style-type: none"> <li>✓ Apresenta, geralmente, forma irregular;</li> <li>✓ A textura pode ser lisa ou mais rugosa;</li> <li>✓ A cor varia em tons de lilás;</li> <li>✓ As áreas de solo exposto estão situadas na área urbana do município;</li> <li>✓ A área degradada do lixão de Presidente Prudente está localizada à esquerda da Rodovia Raposo Tavares (SP-270), próxima à Cidade da Criança.</li> </ul> |

Com base na chave de interpretação foram coletadas as amostras de treinamento para as nove classes de cobertura identificadas na cena. Para tanto, as bandas TM foram importadas para o aplicativo IDRISI. Ao coletar o conjunto de treinamento foi considerada como regra a seleção de mais que  $10N$  *pixels* para cada classe, onde  $N$  é o número de bandas disponíveis (JENSEN, 1996; RICHARDS; JIA, 1999). Além disso, buscaram-se amostras representativas que abrangessem a máxima variabilidade das classes, coletando elementos amostrais nas regiões “intra-classes” (dentro das classes) e “entre classes” (de transição entre certas classes). Isso é necessário visto que *pixels* mistos podem ocorrer tanto no interior de classes, devido à resolução espacial do sensor, quanto nas bordas de classes, visto que a transição entre tipos de cobertura naturais é geralmente gradual.

Ao contrário de uma classificação convencional, onde, normalmente, é recomendada a seleção de amostras homogêneas representativas para as classes, em uma classificação *fuzzy* devem ser adquiridas amostras de treinamento *fuzzy*, as quais são caracterizadas pela ocorrência de *pixels* mistos. Essa técnica de classificação busca acomodar a mistura de classes que costuma ocorrer em imagens de resolução espacial mais grosseira,

visando representar com maior confiabilidade as classes de cobertura da terra, proporcionando um mapeamento de melhor qualidade temática.

Após a coleta das amostras de treinamento foi realizada a seleção das bandas (ou atributos) que permitissem o maior grau de separabilidade estatística entre as classes de cobertura. Esse procedimento foi adotado para selecionar apenas as bandas mais úteis à discriminação das classes de interesse, evitando utilizar bandas que pudessem desfavorecer ou mesmo degradar a qualidade do mapeamento. Nesse caso, para a seleção das bandas optou-se por utilizar a técnica estatística denominada divergência transformada ( $DT_{ij}$ ). Essa é uma modificação da medida de divergência ( $D_{ij}$ ), que fornece uma probabilidade *a priori* de classificação correta usando a separabilidade estatística baseada no grau de sobreposição das distribuições de probabilidade entre um par de classes espectrais (RICHARDS; JIA, 1999). Assim, quanto maior a divergência transformada, maior a distância estatística entre as assinaturas de treinamento e, conseqüentemente, maior a probabilidade de classificação correta. Essa medida pode ser computada pela Equação:

$$DT_{ij} = 2.000 \left[ 1 - \exp\left(\frac{-D_{ij}}{8}\right) \right]; \quad (26)$$

onde:

$$D_{ij} = \frac{1}{2} Tr[(\Sigma_i - \Sigma_j)(\Sigma_i^{-1} - \Sigma_j^{-1})] + \frac{1}{2} Tr[(\Sigma_i^{-1} - \Sigma_j^{-1})(\bar{m}_i - \bar{m}_j)(\bar{m}_i - \bar{m}_j)^T]; \quad (27)$$

sendo que:  $i$  e  $j$  são as duas classes a serem comparadas;  $Tr$  é o traço de uma matriz (isto é, a soma dos elementos da diagonal);  $\Sigma_i$  e  $\Sigma_j$  são as matrizes de covariância das duas classes; e  $\bar{m}_i$  e  $\bar{m}_j$  são os vetores média dessas classes. A Equação 26 indica que a divergência transformada aumenta com a distância entre as classes e, normalmente, varia entre 0 e 2.000, cujo valor máximo sugere uma ótima separabilidade e valores abaixo de 1.700 sugerem uma pobre separabilidade (JENSEN, 1996).

A seleção das melhores bandas para a classificação foi realizada no aplicativo IDRISI. Para tanto, as exigências prévias são coletar os elementos amostrais para as classes temáticas; gerar as assinaturas para essas classes, ou seja, extrair os parâmetros estatísticos; e indicar a quantidade de bandas de interesse, a fim de obter a melhor





combinação. Como as amostras de treinamento já haviam sido coletadas, fez-se a extração dos parâmetros para as classes a partir do conjunto total de bandas. Então, sabendo-se que, através da medida de divergência transformada, a separabilidade é computada para cada par de classes,  $C$  combinações possíveis foram avaliadas para cada classe, conforme o número de bandas pré-estabelecido.

Nessa aplicação, como se dispunha de seis bandas TM optou-se por computar a separabilidade para as várias combinações de bandas possíveis, desde seis, isto é, mantendo o conjunto original de dados, até duas bandas. Após computar todas as combinações é apresentada a separabilidade média do conjunto total de assinaturas, calculada como a média de todos os pares de combinações obtidos para cada classe. As melhores médias são apresentadas na Tabela 17.

Tabela 17: Melhores índices de separabilidade média obtidos pela medida de divergência transformada.

| Número de Bandas | Separabilidade Média | Combinação de Bandas TM |
|------------------|----------------------|-------------------------|
| 6                | 1.977,29             | 1,2,3,4,5,7             |
| 5                | 1.993,98             | 2,3,4,5,7               |
| 4                | 1.956,92             | 2,3,4,7                 |
| 3                | 1.844,90             | 2,3,4                   |
| 2                | 1.643,51             | 2,3                     |

Como pode ser observado na Tabela 17, a medida de divergência transformada indicou que a maior separabilidade média foi proporcionada pela combinação de cinco bandas, descartando a banda TM1 do conjunto original de dados. Portanto, essas foram as bandas selecionadas para a classificação.

Após a coleta dos elementos amostrais e seleção de atributos fez-se a definição da matriz de partição *fuzzy*, a qual indica os graus de pertinência de cada conjunto de amostras de treinamento para cada classe. Uma matriz de partição *fuzzy* é construída como uma tabela da seguinte forma:

- Na primeira coluna constam identificadores numéricos inteiros para representar o conjunto de amostras de treinamento coletado para cada classe temática. Por exemplo, como existem oito classes de interesse, nesse caso existirão oito identificadores numéricos (de 1 a 8) para representar cada conjunto de amostras. Esses identificadores devem ser alocados em ordem crescente, um em cada linha da matriz;
- As colunas restantes da matriz de partição devem ser criadas conforme a quantidade de classes de cobertura existentes. Considerando que existem oito



classes, então devem ser criadas oito colunas, cada qual apresentando o nome de uma das classes.

Logo, as linhas da matriz de partição *fuzzy* representam os conjuntos de amostras de treinamento e as colunas, as classes temáticas. Assim, para  $N$  classes e  $M$  conjuntos de treinamento, tem-se uma matriz  $N \times M$ . Essa matriz, construída a partir das nove classes de interesse ao mapeamento em escala regional, pode ser vista na Tabela 18:

Tabela 18: Matriz de partição *fuzzy*.

| $M \backslash N$ | EUR  | MV   | CA | PT   | AUC  | AC   | FF   | ASV  |
|------------------|------|------|----|------|------|------|------|------|
| 1                | 0,85 | 0,10 | 0  | 0    | 0    | 0    | 0    | 0,05 |
| 2                | 0    | 1    | 0  | 0    | 0    | 0    | 0    | 0    |
| 3                | 0    | 0    | 1  | 0    | 0    | 0    | 0    | 0    |
| 4                | 0    | 0    | 0  | 0,86 | 0,06 | 0    | 0,08 | 0    |
| 5                | 0    | 0    | 0  | 0    | 0,80 | 0,14 | 0,06 | 0    |
| 6                | 0    | 0    | 0  | 0    | 0    | 1    | 0    | 0    |
| 7                | 0    | 0    | 0  | 0    | 0    | 0    | 1    | 0    |
| 8                | 0    | 0    | 0  | 0    | 0    | 0    | 0    | 1    |

onde: EUR = Edificação urbana / rural; MV = Malha viária; CA = Cultura agrícola; PT = Pastagem; AUC = Área úmida continental; AC = Água continental; FF = Formação florestal; e ASV = Área sem cobertura vegetal.

Na Tabela 18 pode-se verificar que, para o conjunto de amostras de treinamento coletado para a classe EUR (*Edificação urbana / rural*), por exemplo, foi estimada uma proporção de 85% de ocorrência da classe propriamente dita; uma proporção de ocorrência da classe MV (*Malha viária*) equivalente a 10%; e, ainda, uma proporção de 5% para a classe ASV (*Área sem cobertura vegetal*). Dessa forma, os graus de pertinência estimados para as classes EUR, MV e ASV foram 0,85, 0,10 e 0,05, respectivamente. Essa estimativa é feita com base nos dados de treinamento coletados para cada classe e os graus de pertinência são atribuídos considerando o conhecimento que o analista tem de interpretação de imagem e da área mapeada. Quando nenhuma proporção de mistura é considerada dentro do conjunto de amostras de treinamento, o valor 1 é atribuído à classe, como, por exemplo, para a classe AC (*Água continental*).

Elaborada a matriz de partição *fuzzy*, foi realizada a extração de assinaturas *fuzzy* para as classes de cobertura. Diferente do procedimento de extração de assinaturas convencional, que simplesmente fornece os parâmetros estatísticos para as classes, esse processo gera uma saída na qual é atribuído, a cada *pixel*, um peso proporcional ao seu grau de pertinência nas estimativas da média, variância e covariância de cada banda em relação a cada classe temática de interesse. Assim, um *pixel* que é, predominantemente, composto de



*Formação florestal*, por exemplo, terá um grande peso na determinação da assinatura referente a essa classe, mas um peso baixo na determinação da assinatura para outras classes constituintes.

Em seguida pôde-se aplicar o classificador relativo bayesiano, sendo consideradas probabilidades *a priori* iguais para todas as classes. Como resultado do processamento tem-se um conjunto de imagens (uma por classe) que expressa a probabilidade *a posteriori* dos *pixels* pertencerem a cada uma das classes de cobertura da terra. Na Figura 16, por exemplo, são apresentadas as imagens de probabilidade *a posteriori* para as classes *Edificação urbana / rural* (A) e *Pastagem* (B). Conforme a escala de tons de cinza, no caso da imagem A, verifica-se a alta probabilidade *a posteriori* principalmente dos *pixels* representativos da mancha urbana situada ao sul do município. Em relação à imagem B, nota-se que grande parte da área do município apresenta alta probabilidade *a posteriori* de pertencer à classe *Pastagem*.

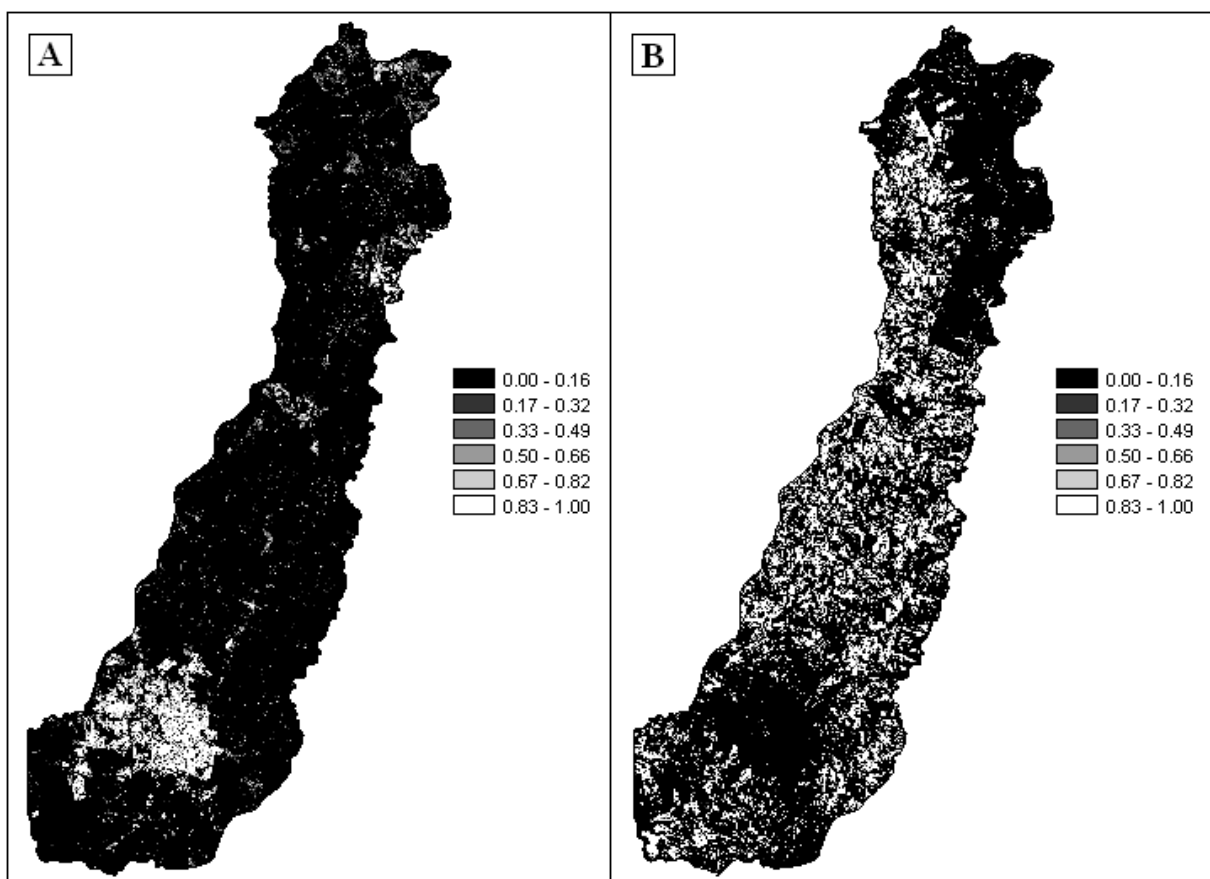


Figura 16: Imagens de probabilidade *a posteriori* para as classes *Edificação urbana / rural* (A) e *Pastagem* (B), fornecidas pelo classificador relativo bayesiano.

Finalmente, foi gerada uma saída rígida (convencional) para a classificação relativa, a qual pode ser chamada de imagem classificada *fuzzy*. Nesse processo, denominado *defuzificação*, a partir das imagens de probabilidade *a posteriori* fornecidas para cada *pixel* em relação a cada classe, a imagem classificada *fuzzy* é produzida com a atribuição do *pixel* à classe na qual este apresenta maior probabilidade de pertencer, ou seja, probabilidade máxima, ignorando as demais proporções de contribuição de outras classes. Para melhor explicitar essa etapa, tomou-se como exemplo supostas imagens de probabilidade *a posteriori* produzidas por quatro classes de cobertura genéricas e, a partir destas, foi gerada a imagem classificada *fuzzy*, como ilustra a Figura 17. Trata-se de uma estratégia tipicamente utilizada para geração de imagem convencional a partir de classificações baseadas em abordagem *fuzzy*.

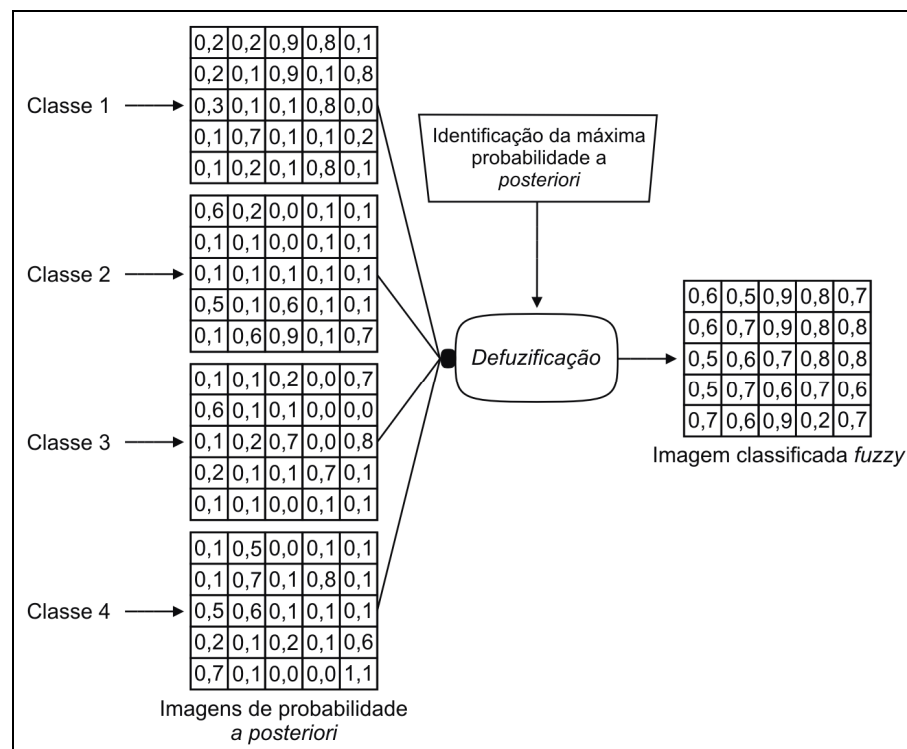


Figura 17: Processo de defuzificação a partir das imagens de probabilidade a posteriori.

Fonte: Adaptado de ISLAM (2004).

A geração de uma saída convencional é importante e necessária. Primeiro, os usuários estão mais acostumados a lidar com esse tipo de informação sendo, portanto, essencial dispor de um mapa classificado que auxilie aos projetos de planejamento e as tomadas de decisão. Além disso, esse é um procedimento necessário à etapa da análise da acurácia da classificação fornecida pelos coeficientes estatísticos tradicionalmente utilizados.

O produto gerado também pode ser comparado com mapeamentos futuros, desde que os critérios estabelecidos para a descrição das classes de cobertura sejam os mesmos.

A experiência mostra que, apesar do potencial das imagens de sensoriamento remoto para a elaboração de mapeamentos temáticos, dificilmente os produtos são gerados sem algum componente de subjetividade, visto que nem sempre se consegue discriminar adequadamente todos os tipos de cobertura da terra de interesse, em especial classes que apresentam comportamento espectral similar. Nem mesmo a técnica mais eficiente de classificação é capaz de gerar um resultado sem erros. Assim, edições posteriores tornam-se necessárias para adequar os resultados da classificação a algumas classes de interesse e corrigir outras inconsistências.

Dessa forma, processos de pós-classificação foram aplicados à imagem classificada *fuzzy*. Inicialmente, visto que o classificador automático por *pixel* gera uma grande quantidade de *pixels* isolados, optou-se por aplicar um filtro da moda (ou filtro majoritário), considerando uma máscara 3x3, que permitiu eliminar *pixels* isolados associados a classes diferentes da predominante. O filtro da moda “varre” a imagem digital (nesse caso, a imagem classificada), identifica os valores digitais sob a máscara e atribui o valor digital predominante (ou seja, a moda) ao valor central da máscara, eliminando valores discrepantes e, conseqüentemente, suavizando a imagem.

Outra etapa de pós-classificação foi a edição de algumas regiões de *Solo preparado / Cultura recém-colhida*, pertencentes à classe *Cultura agrícola* e localizadas ao norte da área de estudo, as quais foram erroneamente atribuídas à classe *Edificação urbana / rural*, devido à semelhança espectral dos alvos. Ainda, edições foram necessárias no sentido de melhorar a representação do tipo de cobertura *Malha viária*, visto que pôde-se observar descontinuidades nas linhas classificadas. Esses processos de edição temática foram realizados no aplicativo SPRING.

Com isso foi gerado o mapa temático da cobertura da terra do município de Presidente Prudente, a partir das subclasses definidas no nível II do sistema hierárquico de classificação em escala regional. Esse mapeamento é apresentado no Apêndice A, que constitui uma carta temática produzida com a inserção das informações cartográficas convencionalmente utilizadas.

A partir do resultado do mapeamento foram estimadas as proporções de cobertura de cada classe presente na área de estudo. Essas proporções são apresentadas na Tabela 19, em hectare (ha) e em porcentagem (%).



Tabela 19: Proporção de ocorrência estimada para as classes do mapeamento em escala regional.

| <i>Classe de cobertura</i> | <i>Hectare (ha)</i> | <i>Porcentagem (%)</i> |
|----------------------------|---------------------|------------------------|
| Edificação urbana / rural  | 5.806               | 10,3                   |
| Malha viária               | 620                 | 1,1                    |
| Cultura agrícola           | 11.725              | 20,8                   |
| Pastagem                   | 22.100              | 39,2                   |
| Área úmida continental     | 4.228               | 7,5                    |
| Água continental           | 451                 | 0,8                    |
| Formação florestal         | 11.275              | 20,0                   |
| Área sem cobertura vegetal | 169                 | 0,3                    |
| Total                      | 56.374              | 100                    |

Conforme é observado na Tabela 19, a cobertura predominante no município foi *Pastagem* com, aproximadamente, 39,2% da área total. A alta proporção dessa classe é esperada, visto que a região na qual se insere o município tem tradição em pecuária, principalmente com a criação de bovinos. Além disso, a criação de eqüinos, suínos e aves também é uma prática comum em Presidente Prudente, porém, menos representativa (IBGE, 2007b).

A classe *Cultura agrícola* representou a segunda maior proporção de cobertura, equivalente a 20,8%, sendo composta por áreas com cultura plantada e também com solo preparado ou com cultura recém-colhida. Essas áreas, em sua maioria, estão relacionadas com o cultivo de cana-de-açúcar, que caracteriza a paisagem da região norte do município. A tendência para os próximos anos é, cada vez mais, a expansão do plantio desse tipo de cultura, com o incentivo do governo às exportações e com o uso da cana para a fabricação de álcool, açúcar e energia. Essa prática tem-se mostrado uma alternativa mais rentável do que a manutenção da terra para a pecuária, e novas usinas já surgiram e foram instaladas na região. Com isso, embora essa tendência possa ser economicamente interessante para o município e região, preocupações surgem decorrentes dos danos ambientais que essa prática poderá trazer, tais como o aumento das queimadas e dos desmatamentos.

A classe *Formação florestal* representou 20% da área do município, constituindo a terceira maior proporção de cobertura. Embora essa porcentagem, a princípio, pareça significativa, sabe-se que o município é formado por cerca de 80% de área rural, que, no passado, era basicamente composta por floresta. Essa proporção torna-se ainda menos significativa e preocupante ao somar os percentuais de cobertura referentes à *Pastagem* e à *Cultura agrícola*, estimando cerca de 60% de área de floresta desmatada para o desenvolvimento da agropecuária no município.

A cobertura do município referente à *Área úmida continental* e *Água continental* no mapeamento representou em torno de 7,5% e 0,8%, respectivamente. O



primeiro tipo de cobertura está localizado, basicamente, próximo a rios e córregos, e o segundo é formado por duas represas e por outros corpos d'água menos representativos. Vale destacar que a resolução espacial do sensor, nesse caso, não possibilitou o mapeamento dos cursos d'água de menor dimensão, os quais existem em grande parte da área do município e que são percebidos pela floresta ciliar existente no entorno.

Finalmente, as proporções das classes *Edificação urbana / rural* e *Malha viária* corresponderam a 10,3% e 1,1%, respectivamente, sendo localizadas na região sul do município, principalmente. Ainda, a classe *Área sem cobertura vegetal* representou 0,3% da cobertura municipal, sendo parte desse percentual relacionado ao lixão de Presidente Prudente que, apesar de significar uma porcentagem pequena se comparada à extensão territorial total, é sabido sobre o enorme potencial de degradação ambiental dessa área e da necessidade, desde muito tempo, de solucionar esse problema.

### 6.4.3 Análise da confiabilidade do mapeamento

A classificação baseada em abordagem *fuzzy* permite que a análise da confiabilidade do mapeamento seja feita de duas maneiras: (i) a partir do cálculo de métricas estatísticas indicadoras da acurácia do mapeamento; e (ii) por meio de medidas de incerteza associadas ao processo de decisão de atribuição dos *pixels* às classes.

Convencionalmente, para avaliar a acurácia de uma classificação é utilizada a matriz de erros, que compara dados de referência com o resultado do mapeamento, sendo essa a estratégia utilizada nesta pesquisa. A realização dessa análise pressupõe, inicialmente, a definição de alguns parâmetros, tais como: esquema de amostragem; quantidade de elementos amostrais; tipo de unidade amostral; e dados de referência.

Nessa aplicação, optou-se por utilizar o esquema de amostragem aleatório estratificado, que combina boa distribuição geográfica com menor potencial de tendência. Essa estratégia de amostragem é particularmente útil por garantir que todas as classes sejam amostradas, mesmo as de baixa proporção de ocorrência, como é o caso das classes *Água continental* e *Área sem cobertura vegetal*.

Para estimar o número de elementos amostrais para cada classe foram consideradas as Equações 16 e 17. O valor da estatística qui-quadrado foi computado no



aplicativo R, sendo equivalente a  $\chi^2_{(1,0,99375)} = 7,476773$ , para um nível de confiança de 95%. O valor da precisão desejada ( $d_i$ ) foi assumido como 5% e as proporções representativas de cada classe ( $p_i$ ) foram aquelas estimadas para o mapeamento (Tabela 18). Por exemplo, para a classe *Pastagem*, de maior representatividade na área de estudo, o número mínimo de amostras correspondeu a 90 e, para as demais classes, com menor proporção de ocorrência, os valores obtidos foram inferiores a este, totalizando 278 amostras. Assim, para cada classe foi possível calcular o número mínimo de amostras necessárias para a análise, em função da proporção de cobertura. Para gerar essas amostras e distribuí-las sobre a área de estudo, em um esquema aleatório estratificado, foi utilizado o aplicativo IDRISI.

A unidade amostral utilizada foi um conjunto de  $2 \times 2$  *pixels*. Ou seja, sobre cada amostra fornecida pelo esquema amostragem foi gerada uma máscara  $2 \times 2$ , a fim de definir a imagem de referência (ou “verdade terrestre”). Para gerar as máscaras sobre os elementos amostrais, dando origem à imagem de referência, foram consideradas as seguintes informações: o conhecimento da área de estudo; imagens de alta resolução espacial disponibilizadas pelo aplicativo *Google Earth*; e informações do projeto CANASAT (INPE, 2007a) sobre a distribuição espacial da área cultivada com cana-de-açúcar no município.

Após a definição da imagem de referência, esta foi confrontada com o resultado final da classificação, utilizando o aplicativo IDRISI, e dando origem à matriz de erros apresentada na Tabela 20:

Tabela 20: Matriz de erros gerada pela classificação em escala regional.

|               |               | Verdade Terrestre |     |     |     |    |     |    | $\sum x_{i+}$ |
|---------------|---------------|-------------------|-----|-----|-----|----|-----|----|---------------|
|               |               | 1                 | 3   | 4   | 5   | 6  | 7   | 8  |               |
| Classificação | 1             | 125               | 15  | 9   | 5   | 0  | 0   | 2  | 156           |
|               | 3             | 11                | 228 | 14  | 0   | 0  | 0   | 4  | 257           |
|               | 4             | 5                 | 29  | 320 | 16  | 3  | 7   | 0  | 380           |
|               | 5             | 4                 | 0   | 6   | 95  | 2  | 8   | 0  | 115           |
|               | 6             | 0                 | 0   | 0   | 0   | 18 | 0   | 0  | 18            |
|               | 7             | 0                 | 5   | 8   | 13  | 0  | 210 | 0  | 236           |
|               | 8             | 2                 | 1   | 0   | 0   | 0  | 0   | 11 | 14            |
|               | $\sum x_{+j}$ | 147               | 278 | 357 | 129 | 23 | 225 | 17 | 1176          |

onde: 1 = Edificação urbana / rural; 3 = Cultura agrícola; 4 = Pastagem; 5 = Área úmida continental; 6 = Água continental; 7 = Formação florestal; 8 = Área sem cobertura vegetal.





O que primeiro pode ser observado na Tabela 20 é que a classe *Malha viária* foi desconsiderada nessa análise, visto que tal classe compreende feições temáticas lineares e não de área. Assim, não seria viável coletar os elementos amostrais necessários à análise.

A matriz de erros mostra que todas as classes de cobertura proporcionaram confusão na classificação, o que, em geral, é esperado por se tratar de classes com resposta espectral similar, bem como de um mapeamento em escala regional onde existe maior proporção de mistura de coberturas. Dessa forma, do total de 1176 *pixels* analisados, 169 *pixels* foram classificados erroneamente, ou seja, cerca de 14,37% do total do conjunto de amostras verificadas. Como consequência, a exatidão global ( $P_o$ ) computada foi de 85,63%.

O valor de exatidão global obtido para esse mapeamento satisfaz o que propõem Anderson et al. (1976). Segundo os autores, índices de exatidão global devem ser de, no mínimo, 85% para que as classificações possam ser utilizadas como referência aos planejamentos e tomadas de decisão. Contudo, classificações que fiquem aquém do desejável não devem, necessariamente, ser consideradas como inválidas, visto que as classificações automáticas, em geral, apresentam índices de exatidão não muito elevados.

Quanto mais complexa a paisagem a ser mapeada, pior tende a ser o resultado da acurácia do mapeamento. Nessa aplicação em particular, não houve a necessidade de uma grande quantidade de processamentos para obter um grau de exatidão global aceitável, visto que a área de estudo não se configura em uma paisagem muito complexa, ou seja, em grande parte é formada por pastagens e áreas destinadas à cultura agrícola, além de ser desprovida de relevo acidentado, que ocasionaria sombreamento nas imagens orbitais dificultando o mapeamento. Provavelmente, se a mesma classificação fosse realizada em uma área de Cerrado, isto é, se fossem consideradas as subclasses do nível II do sistema hierárquico em escala regional, outros processamentos prévios seriam necessários de forma a garantir um mapeamento de qualidade satisfatória, uma vez que as regiões do Cerrado configuram-se paisagens mais complexas que a considerada nesta pesquisa. Entende-se aqui que o termo “satisfatória” varia em função da finalidade que se pretende para cada mapeamento. Por exemplo, em alguns casos se tem interesse em mapear culturas agrícolas para estimativas de área plantada e de tipo de cultura predominante na região em questão. Assim, a qualidade satisfatória do mapeamento deve estar relacionada, principalmente, às áreas agrícolas, sendo menos importantes as demais áreas antrópicas e naturais.



Em suma, a acurácia de um mapa depende de muitos fatores, incluindo a quantidade de esforços (processamentos), o nível de detalhe definido no projeto de classificação e a variabilidade das classes a serem mapeadas. Em algumas aplicações, uma acurácia global de 85% é mais que suficiente, mas, em outros casos, essa não seria uma acurácia aceitável. Logo, depois que os mapas foram avaliados de maneira global, existe a necessidade de avaliar as categorias individualmente.

Outros indicadores da exatidão global da classificação calculados nessa análise foram os índices de concordância *Tau* ( $\tau$ ) e *Kappa* ( $\hat{\kappa}$ ), com valores correspondentes a 83,58% e 81,67%, respectivamente. O gráfico da Figura 18 mostra os percentuais de concordância obtidos para os três índices computados a partir da matriz de erros, ao comparar o mapeamento e a informação de referência. Conforme esperado, a exatidão global tende a representar o valor máximo calculado, visto que considera apenas o percentual correto da matriz e superestima o resultado da classificação. Por outro lado, os coeficientes *Tau* e *Kappa* possuem maior consistência por considerarem para a obtenção do valor final, além do percentual de plena concordância, a proporção de concordância por casualidade. O valor intermediário de *Tau* indica um balanceamento entre os outros dois índices.




Figura 18: Percentuais de concordância computados para os índices totais de acurácia da classificação em escala regional.

Conforme a Tabela 4 (item 3.3.1), o valor obtido para *Kappa* é considerado como um resultado excelente. Contudo, os valores dispostos nessa tabela não são os mais adequados para lidar com dados de sensoriamento remoto, os quais, geralmente, proporcionam resultados de *Kappa* não inferiores a 60%, conforme o que se tem observado na literatura. Dessa forma, dizer que um valor de *Kappa* equivalente a 81,67% é “excelente”

seria como superestimar esse resultado e, assim sendo, acredita-se que é mais adequado dizer que obteve-se um valor “bom” para a estatística *Kappa*.

Para a análise da acurácia por classe, inicialmente foram computadas a exatidão do usuário (*EU*) e a exatidão do produtor (*EP*). O primeiro índice é obtido a partir do resultado da classificação e o segundo, considerando a imagem de referência. Os valores complementares a esses índices referem-se, respectivamente, aos erros de inclusão (*E<sub>I</sub>*) e de exclusão (*E<sub>E</sub>*) das classes mapeadas. Além disso, também foi calculada a concordância *Kappa* por classe. Os valores dessas estatísticas são listados na Tabela 21.

Tabela 21: Índices de exatidão por classe computados para o mapeamento em escala regional.

| Classes de cobertura       | <i>EU</i> (%) | <i>E<sub>I</sub></i> (%) | <i>EP</i> (%) | <i>E<sub>E</sub></i> (%) | $\hat{\kappa}_i$ (%) |
|----------------------------|---------------|--------------------------|---------------|--------------------------|----------------------|
| Edificação urbana / rural  | 80,13         | 19,87                    | 85,03         | 14,97                    | 77,29                |
| Cultura agrícola           | 88,72         | 11,28                    | 82,01         | 17,99                    | 85,22                |
| Pastagem                   | 84,21         | 15,79                    | 89,64         | 10,36                    | 77,33                |
| Área úmida continental     | 82,61         | 17,39                    | 73,64         | 26,36                    | 80,47                |
| Água continental           | 100,00        | 0,00                     | 78,26         | 21,74                    | 100,00               |
| Formação florestal         | 88,98         | 11,02                    | 93,33         | 6,67                     | 86,38                |
| Área sem cobertura vegetal | 78,57         | 21,43                    | 64,71         | 35,29                    | 78,26                |

Conforme pode ser observado na Tabela 21, a classe *Água continental* foi a que apresentou maior exatidão do usuário, ou seja, nenhum *pixel* foi atribuído (classificado) erroneamente a essa classe. Trata-se de um dos alvos mais facilmente discrimináveis, principalmente a partir das bandas adquiridas nos intervalos do infravermelho próximo e médio, onde a radiação eletromagnética sofre forte absorção pelos corpos d’água. Por outro lado, a classe *Área sem cobertura vegetal* proporcionou o menor índice de exatidão do usuário, o que é decorrente do fato de que essa classe apresenta padrões de resposta espectral similares às classes *Edificação urbana / rural* e *Cultura agrícola*, dificultando a discriminação entre essas classes.

Além disso, nota-se que os maiores índices de exatidão do produtor foram computados para as classes *Pastagem* e *Formação florestal*. Com relação à primeira, esse alto índice está relacionado ao fato de que essa classe representa a maior proporção de cobertura da área de estudo. Quando se trata da classe *Formação florestal* é sabido que esse tipo de alvo não costuma oferecer grande dificuldade para discriminação, principalmente quando se dispõe das bandas adquiridas nos intervalos espectrais do vermelho e do infravermelho próximo. Maiores dificuldades são encontradas quando se pretende discriminar tipos de fisionomias vegetacionais requerendo processamentos digitais mais complexos. Por outro lado, a classe *Área sem cobertura vegetal* proporcionou o menor índice de exatidão do produtor, novamente



em decorrência da similaridade espectral com outras classes que fazem parte do mapeamento temático.

Ainda, verifica-se que os valores do índice de concordância *Kappa* por classe são bastante próximos daqueles calculados pela exatidão do usuário, o que se deve ao fato de ambas estatísticas serem computadas considerando, principalmente, os totais marginais proporcionados pelo resultado da classificação. Contudo, embora os resultados sejam similares, Rosenfield e Fitzpatrick-Lins (1986) recomendam considerar o valor de *Kappa* em relação aos demais coeficientes de concordância computados por classe existentes na literatura.

Como dito, em uma classificação baseada em abordagem *fuzzy*, a análise da qualidade temática também pode ser feita através de medidas de incerteza, que são computadas a partir das imagens de probabilidade *a posteriori* fornecidas pelo classificador. Uma imagem de incerteza representa, espacialmente, as regiões com maior potencial de erro quando o classificador é “forçado” a atribuir o *pixel* a uma única classe de cobertura, desconsiderando a resposta gerada pela mistura de duas ou mais classes. Ou seja, a imagem de incerteza permite identificar as regiões com maior potencial de confusão. Assim, enquanto os coeficientes estatísticos fornecem uma medida geral para todo o mapa ou para cada classe, as medidas de incerteza permitem visualizar em quais áreas do mapa temático tais classes têm maior ou menor chance de acerto.

A imagem de incerteza, fornecida pelo classificador relativo bayesiano, foi computada considerando que:

$$Inc(x_i) = 1 - \frac{P_{\max}(x_i) - \left(\frac{P_{\text{som}}(x_i)}{m}\right)}{1 - \frac{1}{m}}; \quad (28)$$

onde:  $P_{\max}(x_i)$  é o valor de probabilidade máxima para o *pixel* ( $x_i$ );  $P_{\text{som}}(x_i)$  é a soma dos valores de probabilidade para aquele *pixel*;  $m$  é o número de classes (assinaturas) consideradas (EASTMAN, 2006). Essa imagem de incerteza foi fatiada em três intervalos: (i)  $< 0.01$ ; (ii)  $0.01 - 0.40$ ; e (iii)  $0.40 - 1.00$ ; sendo mostrada na Figura 19.






Figura 19: Imagem de incerteza gerada pelo classificador relativo bayesiano.

Conforme a escala de cores apresentada na Figura 19, houve um predomínio da cor vermelha na maior parte da área de estudo, que indica uma incerteza variando entre 1% – 40%. Algumas regiões apresentaram incerteza, aproximadamente, nula, visto que os *pixels* correspondem a classes facilmente discrimináveis em relação às demais, tais como *Água continental* e *Formação florestal*, o que implica em altos graus de pertinência para esses *pixels* nas classes em questão e baixa (ou nula) pertinência nas demais. Por outro lado, determinadas regiões da imagem, com *pixels* de maior dificuldade de discriminação, apresentaram maior incerteza, como áreas de *Cultura agrícola*, por exemplo, as quais

apresentam certos padrões de comportamento espectral semelhantes aos verificados para as classes *Área sem cobertura vegetal* e, principalmente, *Edificação urbana / rural*. Ambos os casos são ilustrados na Figura 20.

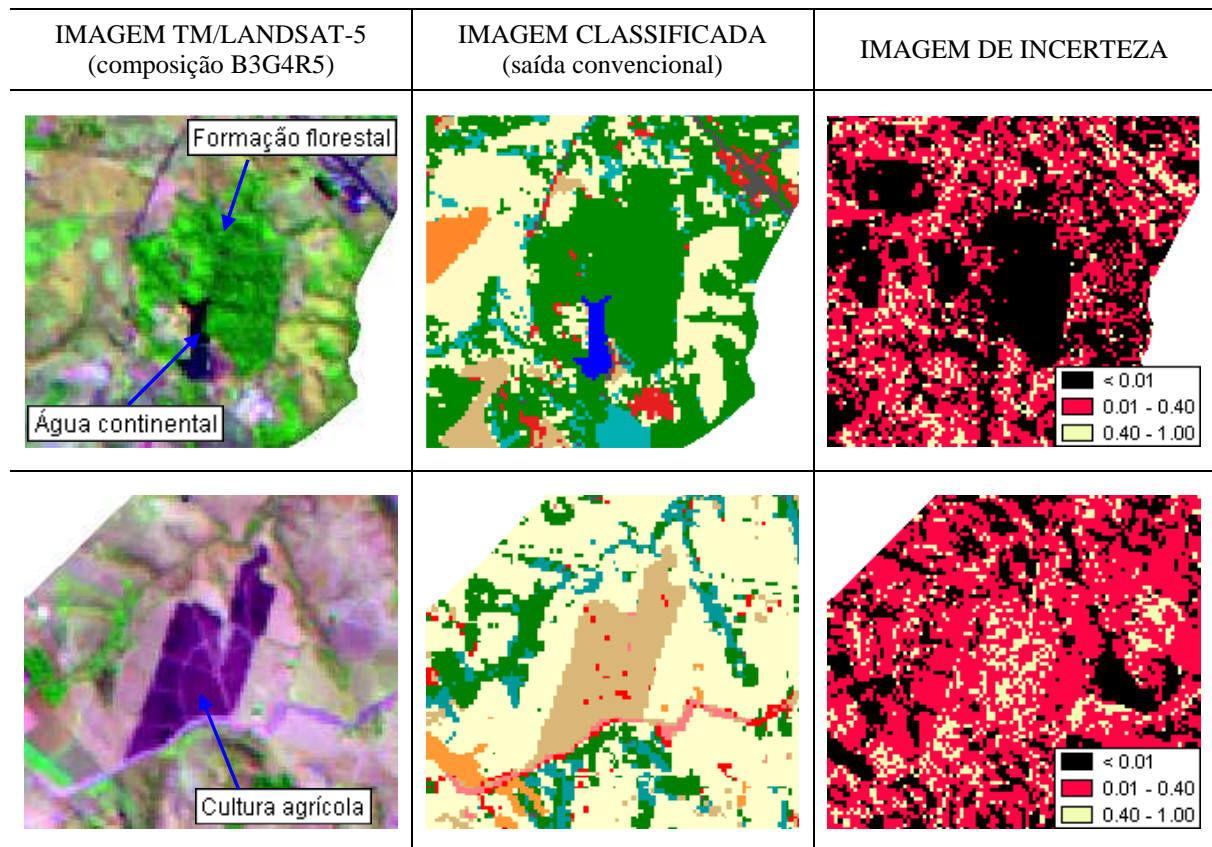


Figura 20: Representações de áreas com menor e maior grau de incerteza ocorrentes na área de estudo.

Imagens de incerteza também podem ser computadas individualmente para cada classe. Como foi mostrado na Figura 16 (item 6.4.2), imagens de probabilidade *a posteriori* são obtidas com a aplicação do classificador relativo bayesiano. A partir disso, considerando a Equação 25 (item 3.3.2), tem-se que a incerteza é o complemento da probabilidade. Ou seja, quanto menor for a probabilidade *a posteriori*, maior será o grau de incerteza para o *pixel* na classe correspondente. Então, se forem consideradas, novamente, as classes *Edificação urbana / rural* (A) e *Pastagem* (B), por exemplo, as imagens de incerteza obtidas para essas classes são apresentadas na Figura 21, onde as regiões mais claras representam os *pixels* com maior grau de incerteza.

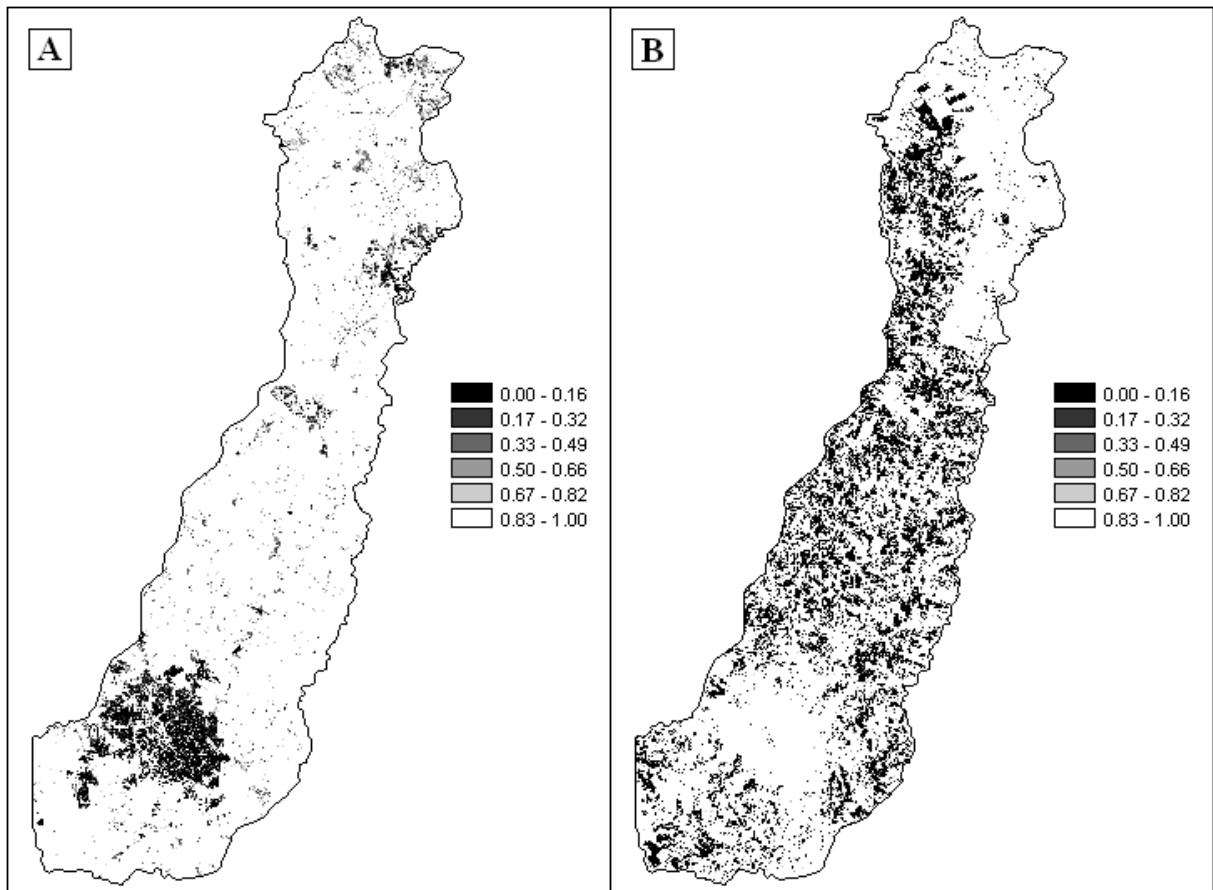


Figura 21: Imagens de incerteza para as classes Edificação urbana / rural (A) e Pastagem (B), mapeadas pelo classificador relativo bayesiano.

Burrough, van Gaans e Hootsmans (1997) também propõem uma medida para avaliar o grau de incerteza (ou ambigüidade) de uma classificação. Essa medida é denominada índice de confusão ( $IC$ ) e pode ser obtida por:

$$IC = 1 - (\mu_{\max_1}(x_i) - \mu_{\max_2}(x_i)); \quad (29)$$

onde:  $\mu_{\max_1}(x_i)$  e  $\mu_{\max_2}(x_i)$  são a primeira e a segunda pertinências máximas das classes para um dado *pixel*, respectivamente. A suposição a partir desse índice é que, quanto maior for o seu valor, menor será a diferença nos valores de pertinência *fuzzy* entre a primeira e a segunda classe mais prováveis, e, conseqüentemente, maior é a probabilidade de que o *pixel* esteja propenso a erro de classificação. Dessa maneira, o índice de confusão também pode ser usado para examinar os padrões espaciais de erros da classificação.

A imagem que expressa o índice de confusão computado a partir das probabilidades *a posteriori* fornecidas pelo classificador relativo bayesiano é apresentada na Figura 22. Como pode ser observado, quatro regiões pertencentes a classes distintas foram

destacadas a partir da imagem e, como esperado, os maiores índices de confusão indicam as classes de maior dificuldade de separabilidade (ex.: b e c), ou seja, com maiores chances de confusão, enquanto os índices mais baixos referem-se a classes facilmente discrimináveis.

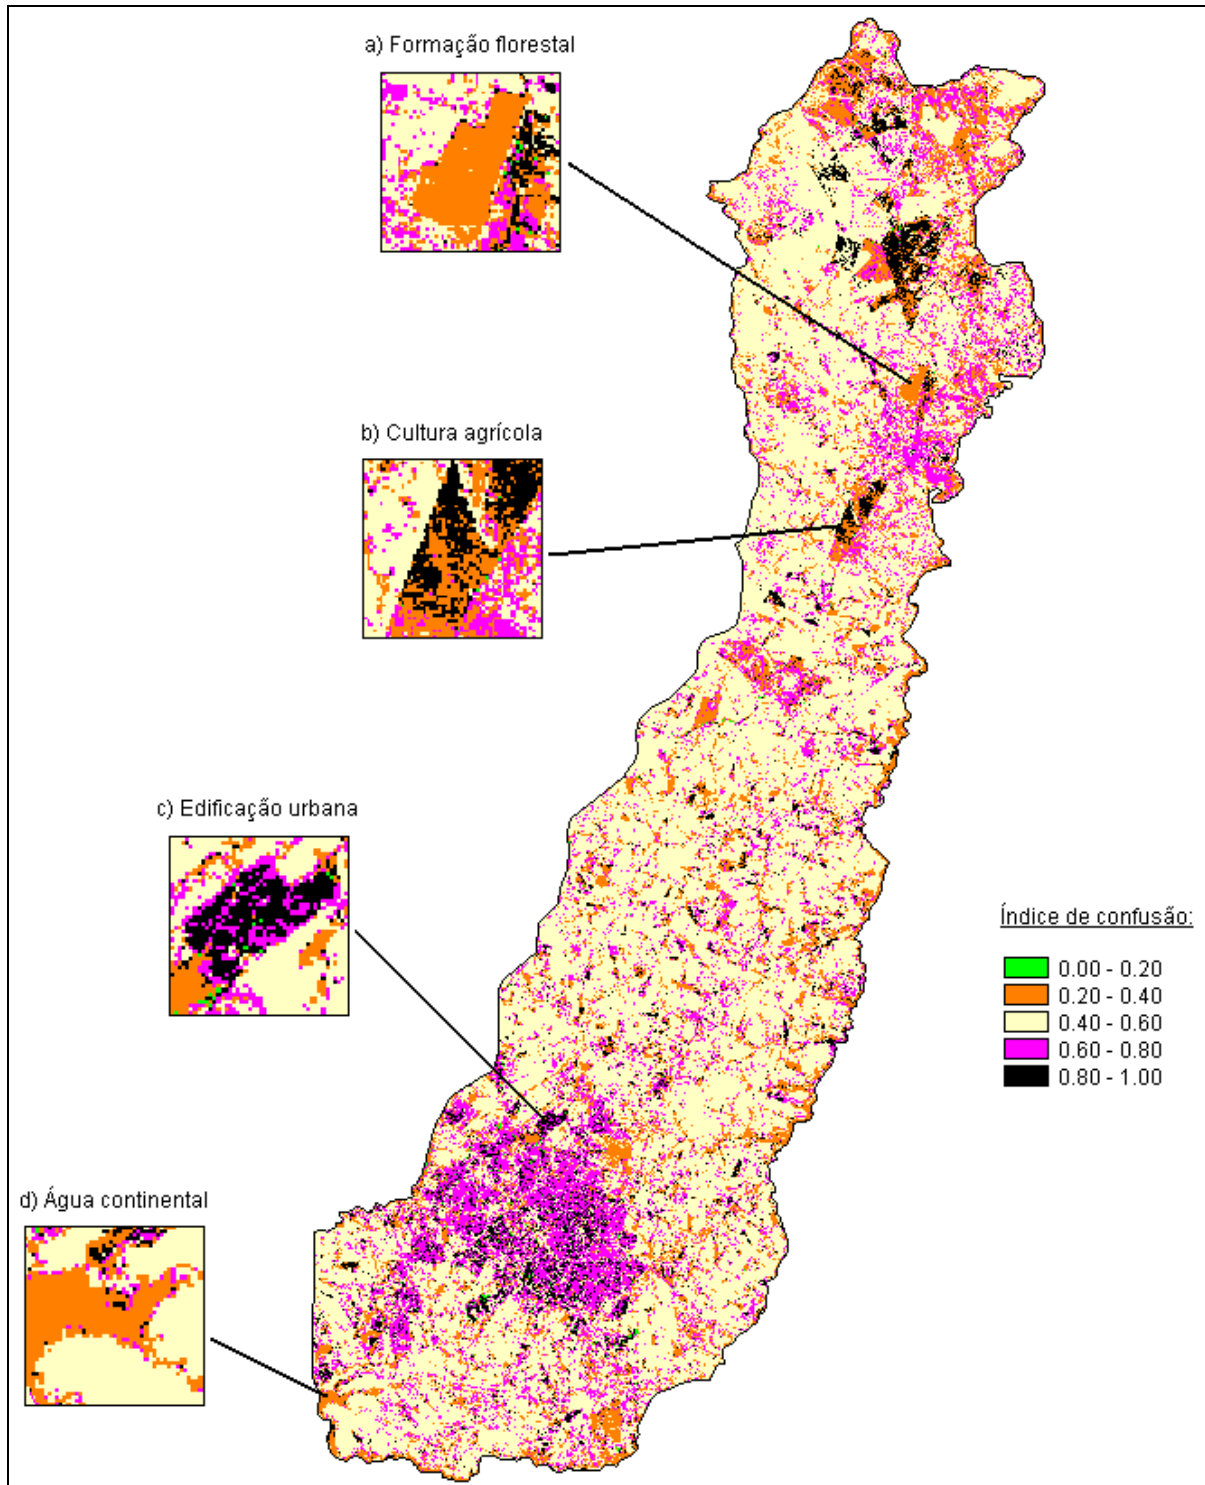


Figura 22: Índice de confusão computado para o classificador relativo bayesiano.



Logo, a partir da análise da incerteza, tanto o usuário quanto o produtor da classificação podem conhecer as regiões mapeadas com maior potencial de erro, o que pode consistir em uma informação útil em se tratando de um mapeamento temático que seja utilizado para a tomada de decisão. As áreas de maior incerteza também podem atuar como indicadores para os processos de pós-classificação, destacando as regiões que precisam ser reclassificadas pelo analista, a fim de gerar um produto final de melhor qualidade e maior confiabilidade.

## 6.5 Processamentos e análises do mapeamento em escala urbana

Os processamentos realizados para o mapeamento em escala urbana consistiram em etapas similares àquelas descritas para a classificação em escala regional. Contudo, nesse caso, houve a necessidade de uma quantidade maior de pré-processamentos, a fim de preparar adequadamente os dados originais para a extração da informação temática de interesse. Finalmente, também foi realizada a análise da qualidade da informação mapeada.

### 6.5.1 Pré-processamentos dos dados

A etapa inicial de pré-processamento consistiu no georreferenciamento do recorte das imagens QuickBird II, as quais estavam com resolução radiométrica reamostrada para 8 bits. Para tanto, novamente foi utilizado o aplicativo SPRING, o qual requer a prévia conversão das bandas em formato TIFF para o formato GRIB através do módulo IMPIMA.

Nessa aplicação, o processo de georreferenciamento envolveu duas etapas. Primeiro foram coletadas coordenadas de pontos de controle identificados na base vetorial do município de Presidente Prudente para realizar o georreferenciamento modo teclado da imagem pancromática. Esse processo utilizou função de transformação linear e interpolação pelo método do vizinho mais próximo, sendo considerados 20 pontos de controle identificados na base vetorial e na imagem pancromática, alcançando uma precisão de 3,14 *pixels* (ou 1,88 metros).



Posteriormente, foi realizado o georreferenciamento modo tela da imagem multiespectral, considerando a imagem pancromática corrigida como referência. Novamente foi considerada função de transformação linear e interpolação pelo método do vizinho mais próximo. A utilização de 20 pontos de controle proporcionou um erro de 0,42 *pixel* (ou 1,01 metros).

Concluído o georreferenciamento, as imagens multiespectrais e pancromática foram exportadas em formato GeoTIFF para que novos pré-processamentos pudessem ser realizados em outros aplicativos. Dentre esses pré-processamentos, inicialmente optou-se por realizar uma operação de fusão de imagens (também denominada *merging*, *fusion* ou *pan-sharpening*), visto que se dispunha tanto de imagem multiespectral quanto pancromática. Nesse processo, bandas multiespectrais de menor resolução espacial são fusionadas com a banda pancromática de alta resolução espacial, a fim de potencializar a alta resolução espacial da banda pancromática e as características espectrais das bandas multiespectrais. Ou seja, com essa operação é possível unir as informações de detalhes da banda pancromática com o conteúdo espectral das demais bandas que possibilita representações coloridas.

Uma variedade de diferentes técnicas de fusão existe na literatura com adaptações específicas para suprir problemas particulares. Dentre esse leque de possibilidades, Pinho, Rennó e Kux (2005) realizaram análises com algumas técnicas usuais aplicadas a imagens QuickBird II e concluíram que os melhores resultados foram proporcionados pelas técnicas por Componentes Principais (CP)<sup>26</sup> e *Gram-Schmidt*<sup>27</sup>. Os autores constataram também que o uso das quatro bandas fusionadas ao invés de apenas três, como em uma aplicação de fusão IHS<sup>28</sup>, proporciona maior capacidade de transferência de detalhes e de conservação do conteúdo espectral.

Por sua vez, Laben e Brower (2000) destacam que, embora a fusão IHS seja a mais comumente utilizada, esta apresenta duas restrições, primeiro em relação ao número de bandas reduzidas que podem ser fusionadas (apenas três), e, além disso, o fato de que essa transformação resulta em alteração do conteúdo espectral. Para a fusão por CP, os citados

---

<sup>26</sup> A técnica de fusão por Componentes Principais é descrita em Carter (1998), Laben e Brower (2000) e Wang et al. (2005).

<sup>27</sup> Os autores responsáveis pela criação da técnica de fusão *Gram-Schmidt*, Laben e Brower (2000), descrevem, nesse trabalho, como foi desenvolvida a transformação de *Gram-Schmidt* (assunto abordado em teorias de Álgebra Linear) e as alterações por eles propostas para a implementação da fusão.

<sup>28</sup> Informações sobre a técnica de fusão IHS podem ser obtidas em Gonzalez e Woods (2000) e em Laben e Brower (2000).



autores dizem que existe a vantagem da possibilidade de uso de um conjunto ilimitado de bandas, contudo, essa técnica resulta em perda de acurácia radiométrica no processo de fusão.

Laben e Brower (2000) enfatizam com clareza que é útil o aumento da resolução espacial proporcionado pelas técnicas tradicionais de fusão, contudo, a integridade espectral dos dados originais tende a ser prejudicada na maioria desses processos. Para atender a ambos os pressupostos, os autores propõem a técnica de fusão baseada na transformação de *Gram-Schmidt*.

A partir dessas considerações, optou-se por fazer uma comparação simples entre as três técnicas mencionadas anteriormente (IHS, por Componentes Principais e *Gram-Schmidt*), utilizando a fusão com quatro bandas, quando possível, conforme recomendado por Pinho, Rennó e Kux (2005). Para tanto, todas as técnicas foram processadas no aplicativo ENVI e, em seguida, foram calculados os parâmetros estatísticos média ( $\bar{m}$ ), desvio-padrão ( $\sigma$ ) e índice de correlação ( $\hat{\rho}$ ) entre as bandas originais e fusionadas (Tabela 22). Conforme pode ser observado, as técnicas por CP e *Gram-Schmidt* proporcionaram menor variação para a média, em relação às bandas originais, indicando uma conservação do brilho da imagem. Para os valores de desvio-padrão, novamente a fusão *Gram-Schmidt* proporcionou os melhores resultados, constatando que o contraste da imagem original foi preservado após a fusão. Conseqüentemente, a técnica de *Gram-Schmidt* foi a que obteve maior correlação com os dados originais. Ou seja, a fusão *Gram-Schmidt*, em geral, foi a que apresentou os melhores resultados quando comparados às bandas originais, em contraste com a fusão IHS que proporcionou os valores mais discrepantes. Essa análise permitiu selecionar a técnica de fusão mais adequada para esta pesquisa, dentre as convencionalmente utilizadas.

Tabela 22: Parâmetros estatísticos calculados para os dados originais e fusionados por diferentes técnicas.

| Imagem              | Banda 1   |          |              | Banda 2   |          |              | Banda 3   |          |              | Banda 4   |          |              |
|---------------------|-----------|----------|--------------|-----------|----------|--------------|-----------|----------|--------------|-----------|----------|--------------|
|                     | $\bar{m}$ | $\sigma$ | $\hat{\rho}$ | $\bar{m}$ | $\sigma$ | $\hat{\rho}$ | $\bar{m}$ | $\sigma$ | $\hat{\rho}$ | $\bar{m}$ | $\sigma$ | $\hat{\rho}$ |
| Original            | 30,3      | 13,6     | 1            | 47,2      | 23,3     | 1            | 37,9      | 21,9     | 1            | 72,5      | 24,2     | 1            |
| IHS                 | 134,9     | 61,2     | 0,48         | 158,1     | 54,9     | 0,50         | 125,9     | 57,8     | 0,66         | ----      | ----     | ----         |
| CP                  | 30,7      | 12,6     | 0,86         | 47,6      | 22,2     | 0,85         | 38,4      | 21,2     | 0,86         | 72,9      | 27,6     | 0,97         |
| <i>Gram-Schmidt</i> | 30,6      | 12,9     | 0,89         | 47,7      | 22,6     | 0,88         | 38,7      | 21,8     | 0,89         | 72,8      | 26,9     | 0,96         |

Para realizar a fusão *Gram-Schmidt* no aplicativo ENVI, o pressuposto inicial dessa operação é que as imagens orbitais estejam georreferenciadas. Com isso podem ser desenvolvidas as etapas da fusão (Figura 23), as quais consistem nas seguintes:



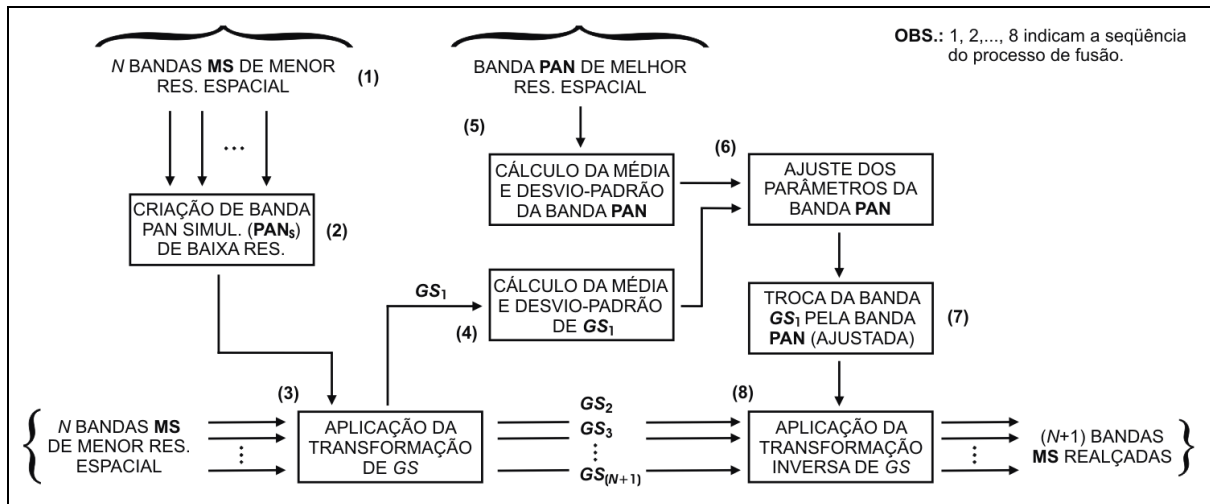


Figura 23: Etapas da técnica de fusão Gram-Schmidt.  
Fonte: Adaptado de Laben e Brower (2000).

- 1) inicialmente é feita a seleção das  $N$  bandas multiespectrais (MS) de menor resolução espacial;
- 2) uma banda pancromática de menor resolução espacial é simulada ( $PAN_S$ ) a partir das bandas MS. Essa banda pan “degradada” pode ser simulada por diferentes procedimentos, sendo que, nesse caso, optou-se por fazer a simulação a partir da média das bandas MS, considerando o sensor em questão;
- 3) a transformação de *Gram-Schmidt* é aplicada à banda  $PAN_S$  e ao conjunto de bandas MS, de modo que a banda  $PAN_S$  é empregada como a primeira banda na transformação (denominada  $GS_1$ );
- 4) as estatísticas média e desvio-padrão de  $GS_1$  são calculadas;
- 5) a banda pancromática (PAN) de resolução espacial mais alta é selecionada e tem seus parâmetros estatísticos calculados;
- 6) as estatísticas da banda PAN são ajustadas para combinar com as estatísticas de  $GS_1$ ;
- 7) a banda  $GS_1$  é substituída pela banda PAN (com estatísticas ajustadas);
- 8) finalmente, a transformação inversa de *Gram-Schmidt* é realizada sobre o novo conjunto de bandas transformadas para produzir as  $(N+1)$  bandas MS de resolução espacial realçada.

Além disso, visto que, na etapa de fusão, a imagem multiespectral com resolução espacial mais grosseira terá o tamanho dos *pixels* reamostrado para a mesma resolução da imagem pancromática, deve-se selecionar o tipo de reamostragem a ser utilizado.

Nesse caso, optou-se pela reamostragem por convolução cúbica, que realiza o ajuste de uma superfície polinomial de terceiro grau para cada *pixel* da imagem em relação aos seus vizinhos. O resultado constitui uma imagem de melhor aparência que a produzida por interpolação pelo método do vizinho mais próximo – de menor interpretabilidade dos alvos decorrente do efeito “serrilhado” –, e sem grande perda de informações de detalhes decorrente do uso de interpoladores bilineares.

Para ilustrar o efeito da fusão da imagem multiespectral com a pancromática QuickBird, foi feito um recorte sobre a composição colorida B1G2R3 formada com as bandas originais (A) e, posteriormente, com o resultado da fusão (B) (Figura 24). Com o aumento da interpretabilidade dos alvos, aumentam-se as possibilidades de aplicações dessas imagens em diversas áreas, tais como planejamento, mapeamento, monitoramento, cadastro, dentre outras.



Figura 24: Composição colorida B1G2R3 formada com as bandas originais (A) e fusionadas (B).

Conforme mencionado no projeto de classificação, embora existam vantagens advindas do uso de imagens de resolução espacial melhorada, dificuldades também são impostas ao processo de classificação, visto que torna-se necessário recorrer a abordagens alternativas às técnicas convencionais de classificação, que lidam apenas com a informação espectral dos dados.

Para aumentar as chances de sucesso em mapeamentos urbanos, estudos têm sido conduzidos sobre o uso de informações de textura (PESARESI, 1999; DEKKER, 2001; FRANKLIN; MAUDIE; LAVIGNE, 2001; HEROLD; LIU; CLARKE, 2003) e de contexto (CAETANO; NAVARRO; SANTOS, 1997; TEEFFELEN; JONG; VAN DER BERG, 2001) na classificação. Particularmente no que se refere a atributos texturais, estes contêm

informações sobre a distribuição espacial de variações tonais em cada banda e são tipicamente derivados a partir de janelas espaciais (7x7, 9x9 etc.) que circundam cada *pixel* da imagem a ser analisada (HARALICK; SHANMUGAM; DINSTEIN, 1973). Ao combinar informações espacial e espectral, a quantidade de sobreposição entre classes pode diminuir, aprimorando a acurácia da classificação.

Dessa forma, nesta pesquisa optou-se por introduzir uma banda de textura, a fim de minimizar o problema da similaridade espectral de alguns alvos, visto que testes preliminares realizados com classificadores convencionais, para a área de estudo selecionada, indicaram, por exemplo, confusão entre as classes *Asfalto* e *Cobertura de fibrocimento* e entre *Solo* e *Cerâmica vermelha*.

Existe uma variedade de tipos de textura descritos na literatura, os quais podem ser subdivididos em três abordagens principais: estrutural, estatística e espectral (GONZALEZ; WOODS, 2000). As abordagens estatísticas são as mais amplamente utilizadas em análise de imagens de áreas urbanas e consistem na obtenção de informações de textura pelo cálculo da dependência espacial dos tons de cinza (ZHANG et al., 2003). Essas abordagens, normalmente, consideram medidas de textura de ocorrência e de co-ocorrência. Dentre essas medidas, optou-se por utilizar a textura de ocorrência por entropia. Outras medidas de ocorrência, tais como *data range*, variância e *skewness* também foram avaliadas, mas não se mostraram tão satisfatórias quanto a entropia. Diferentes tamanhos de janelas espaciais foram testados e selecionou-se uma janela 9x9. Para gerar essa imagem de textura foi utilizado o aplicativo ENVI, onde uma medida de ocorrência é computada considerando o número de ocorrências de cada nível de cinza dentro da janela espacial. Especificamente, a entropia é uma medida da desordem (ou complexidade) da imagem e, assim, é alta quando a imagem não é texturalmente uniforme. Tal medida é computada pela Equação:

$$E(z_i) = -\sum_{i=0}^{L-1} p(z_i) \log_2 [p(z_i)]; \quad (30)$$

onde:  $p(z_i)$  é o histograma de nível de cinza normalizado; e  $L$  é o número de níveis de cinza da imagem ( $0 \leq i \leq L-1$ ) (SHACKELFORD; DAVIS, 2003).

A imagem de textura por entropia é apresentada na Figura 25 e foi gerada considerando a banda pancromática. As medidas de entropia foram superiores, geralmente, nas regiões caracterizadas por feições antrópicas, as quais apresentam maior complexidade espacial, tais como edificações com cobertura de cerâmica e certos tipos de cobertura





metálica. Por outro lado, as feições naturais apresentaram as menores medidas de entropia, incluindo áreas com vegetação e locais onde existem corpos d'água.

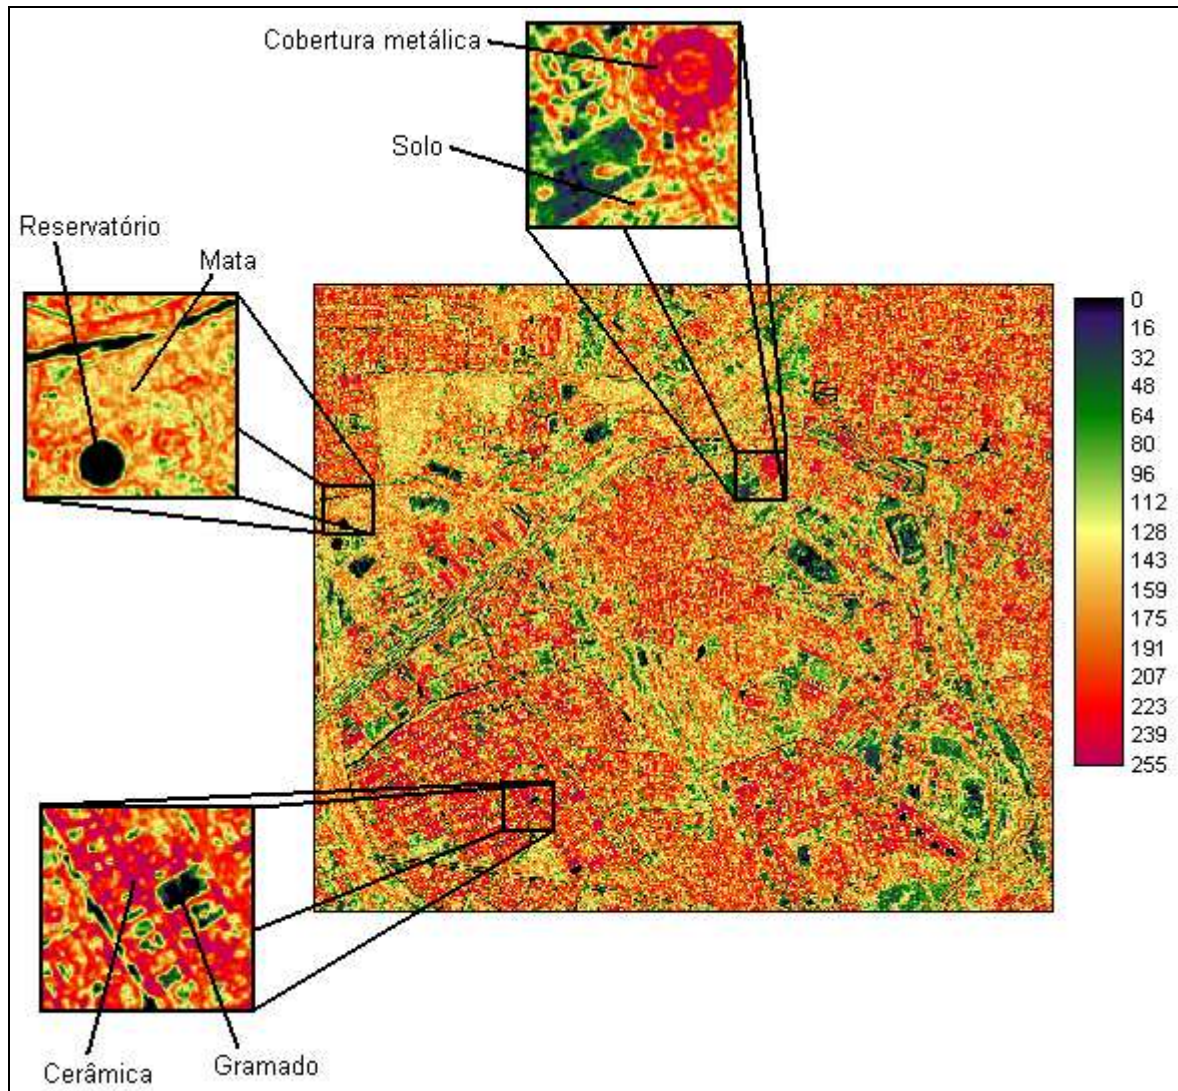


Figura 25: Imagem de textura de ocorrência por entropia.

Com isso, foram finalizados os pré-processamentos. As quatro bandas fusionadas e a imagem de textura foram exportadas do aplicativo ENVI para serem utilizadas como dados de entrada na etapa seguinte de extração da informação temática.

### 6.5.2 Extração e representação da informação temática

A realização de mapeamentos em escala urbana tem sido feita a partir de duas estratégias principais. A primeira delas é pela classificação orientada a objeto (*object-based image classification* – OBIA), a qual considera informações de objetos (ou segmentos) extraídos de uma imagem, no processo de classificação baseada em conhecimento (KIM; XU; MADDEN, 2008). Essa técnica, relativamente recente, tem sido pesquisada e recomendada na literatura (BLASCHKE, 2004; ESTEVAM, 2006; YU et al., 2006). Contudo, o uso dessa abordagem ainda está restrito a uma minoria de especialistas por se tratar de uma técnica pouco difundida, isto é, disponível, até o momento, basicamente no aplicativo *eCognition*, de custo elevado.

A segunda estratégia convencionalmente utilizada para mapeamentos urbanos refere-se às abordagens que permitem utilizar não apenas dados espectrais no processo de classificação, mas também informações adicionais, sejam elas espaciais, de contexto ou mesmo dados auxiliares, sem, necessariamente, serem orientadas a objeto. Dentre essas abordagens, as redes neurais artificiais constituem uma alternativa ainda pouco explorada, porém, vantajosa em relação às técnicas convencionais, pois permitem incorporar outros tipos de dados ao processo de classificação.

Nesta pesquisa, para a aplicação da técnica de rede neural artificial foi utilizado o aplicativo IDRISI, o qual dispõe dessa ferramenta implementada e que consiste no desenvolvimento das etapas ilustradas na Figura 26.





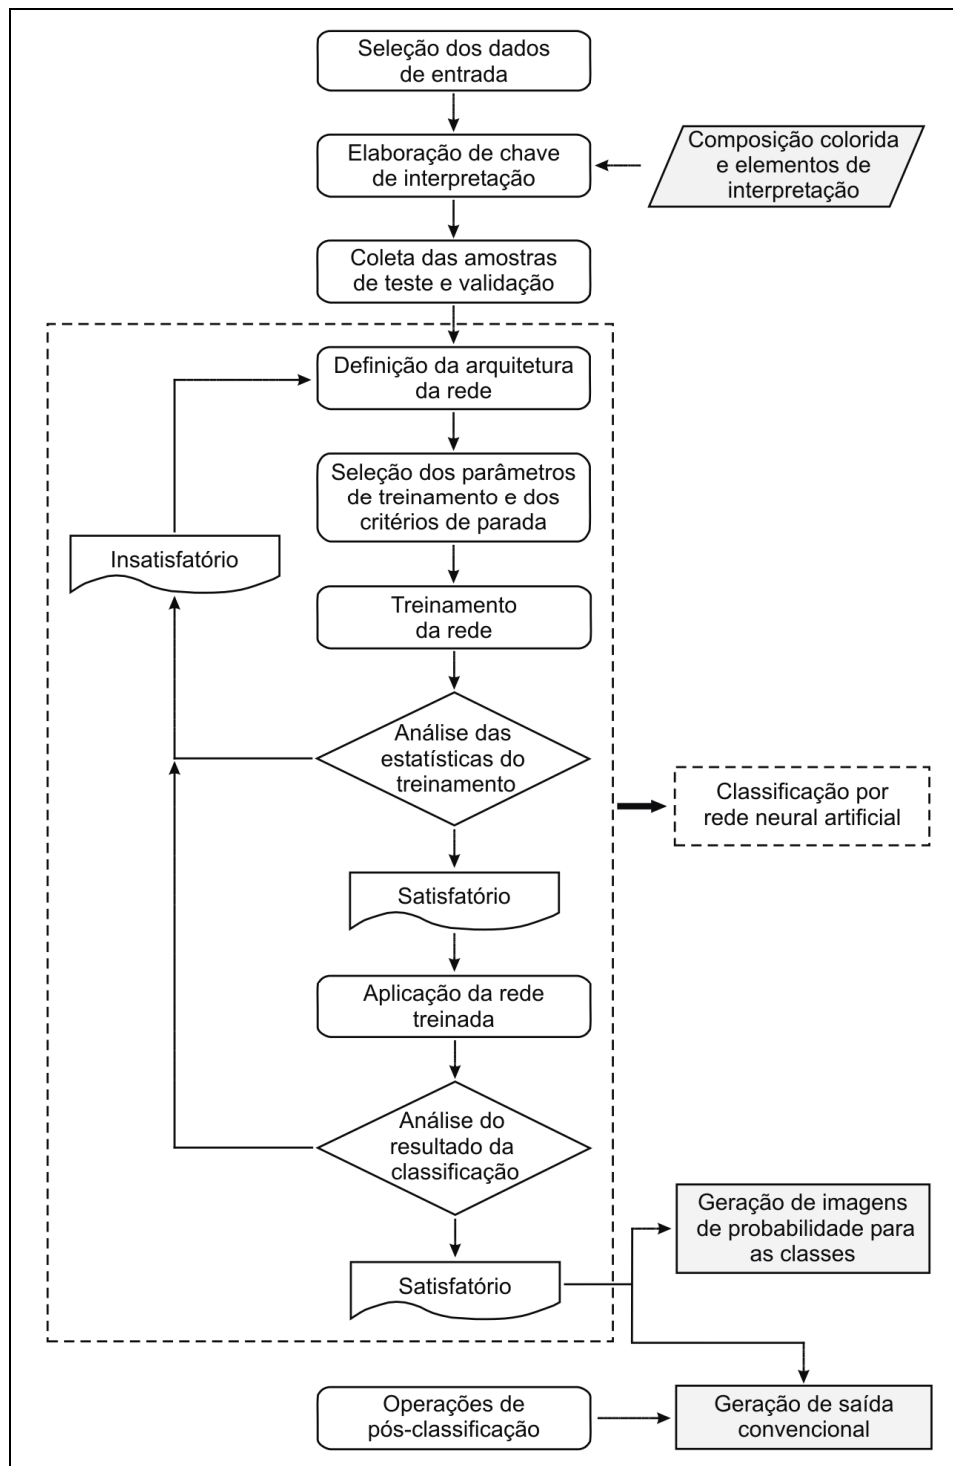

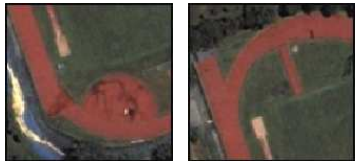




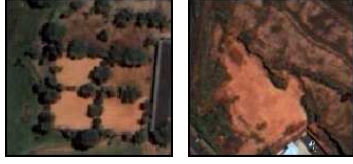




Figura 26: Fluxograma das etapas necessárias à classificação pela rede neural artificial.

A primeira etapa do processo de classificação envolveu a elaboração da chave de interpretação para caracterizar os alvos da cena. Uma coleção de imagens ilustrativas desses alvos e descrições de suas características de reconhecimento são apresentadas na Tabela 23. Para tanto foi considerada a composição colorida verdadeira

B1G2R3 das bandas QuickBird fusionadas, assim como os demais elementos de interpretação.

Tabela 23: Chave de interpretação dos alvos da imagem QuickBird II fusionada.

| ID | Classes                   | Amostras na imagem  | Descrições  |
|----|---------------------------|---|---|
| 1  | Cerâmica                  |    | <ul style="list-style-type: none"> <li>✓ Apresenta forma característica, geralmente com padrões retangulares;</li> <li>✓ O tamanho varia para as edificações menores, mais populares, e as edificações de maior extensão, situadas em regiões nobres;</li> <li>✓ A textura é geralmente lisa;</li> <li>✓ A cor varia em diferentes tons de vermelho, amarelo, azul e cinza.</li> </ul>  |
| 2  | Cobertura de fibrocimento |   | <ul style="list-style-type: none"> <li>✓ Apresenta forma regular, em geral no formato retangular;</li> <li>✓ A textura é rugosa e a cor é cinza médio;</li> <li>✓ É o tipo de cobertura mais popular, utilizado em grandes edificações, como estabelecimentos de ensino, por exemplo, não sendo encontrada em áreas nobres.</li> </ul>  |
| 3  | Concreto                  |  | <ul style="list-style-type: none"> <li>✓ Geralmente, apresenta forma regular;</li> <li>✓ Quando se trata de concreto pintado, como o utilizado em alguns pavimentos e em quadras esportivas, apresenta textura mais lisa que o concreto sujo, mais usual;</li> <li>✓ A cor varia desde tons acinzentados até coloridos, em função do tipo de uso.</li> </ul>  |
| 4  | Cobertura metálica        |  | <ul style="list-style-type: none"> <li>✓ Apresenta forma regular, característica das feições antrópicas urbanas;</li> <li>✓ A textura é lisa, se tornando mais rugosa no caso de coberturas que sofrem processo de corrosão, como certos tipos de aço;</li> <li>✓ A cor é variável, podendo ser branca, azulada, acinzentada e amarronzada;</li> <li>✓ É o tipo de cobertura utilizado exclusivamente para amplos estabelecimentos, de usos comercial, industrial ou hospitalar.</li> </ul> |
| 5  | Asfalto                   |  | <ul style="list-style-type: none"> <li>✓ Apresenta, em geral, forma regular, textura relativamente rugosa e cor cinza.</li> </ul>   |
| 6  | Outros                    |  | <ul style="list-style-type: none"> <li>✓ Apresenta forma regular, cor avermelhada e textura lisa.</li> </ul>  |

|    |                  |   |   |
|----|------------------|---|---|
| 7  | Árvore / Arbusto |    | <ul style="list-style-type: none"> <li>✓ Apresenta forma irregular (característica de alvos naturais), textura rugosa e cor verde;</li> <li>✓ O tamanho da sombra no entorno da vegetação é um indicativo do seu porte.</li> </ul>                                  |
| 8  | Gramado          |    | <ul style="list-style-type: none"> <li>✓ Apresenta forma irregular, textura lisa e cor verde.</li> </ul>  |
| 9  | Solo             |    | <ul style="list-style-type: none"> <li>✓ Apresenta forma irregular e textura geralmente lisa;</li> <li>✓ A cor varia em tons avermelhados mais claros, para as áreas de solo mais seco, e tons avermelhados escuros para as regiões de solo úmido.</li> </ul>       |
| 10 | Sombra           |    | <ul style="list-style-type: none"> <li>✓ Está localizada ao redor de edificações, árvores e arbustos;</li> <li>✓ A presença de sombra é sempre no lado oposto à incidência da luz solar.</li> </ul>   |
| 11 | Curso d'água     |   | <ul style="list-style-type: none"> <li>✓ Apresenta forma irregular, textura lisa e cor escura.</li> </ul>   |
| 12 | Lagoa            |  | <ul style="list-style-type: none"> <li>✓ Apresenta forma irregular e textura lisa;</li> <li>✓ A cor é escura, porém, não tanto quanto o curso d'água, o que indica a ocorrência de maior quantidade de sedimentos em suspensão.</li> </ul>                          |
| 13 | Reservatório     |  | <ul style="list-style-type: none"> <li>✓ Apresenta forma regular e textura muito lisa;</li> <li>✓ A cor varia conforme o tipo de reservatório, desde tons escuros, para os locais de tratamento de água e de efluentes, até coloridos, para as piscinas.</li> </ul> |

Geralmente, a elaboração de chaves de interpretação para mapeamentos em escala urbana tende a ser uma tarefa menos complexa do que para mapeamentos regionais, visto que, normalmente, as pessoas estão em contato constante com as feições urbanas e sua identificação torna-se um processo mais natural. Ou seja, é muito mais simples e direto distinguir tipos de telhados, por exemplo, do que fisionomias vegetacionais.

A partir da definição da chave de interpretação foram coletadas as amostras de treinamento e validação para cada uma das treze classes de cobertura previstas. Nesse processo, as bandas QuickBird fusionadas foram importadas para o aplicativo IDRISI e foi coletado um conjunto adequado de amostras para as classes. Nesse caso, a limitação no número de elementos amostrais foi imposta pela cobertura de menor ocorrência na área de

estudo, que correspondeu à classe *Lagoa*. Ou seja, uma amostra de 1200 *pixels* foi considerada para cada tipo de cobertura, sendo metade do conjunto para o treinamento da rede e o restante para sua validação. Melhor dizendo, esse valor representou a quantidade máxima de *pixels* considerada para cada classe, no momento da aplicação da rede neural artificial, embora um número superior de *pixels* tenha sido coletado para a maioria das classes.

Com a finalidade de analisar a separabilidade estatística entre as classes de cobertura, os dados de treinamento foram usados para calcular a média e o desvio-padrão a partir das quatro bandas fusionadas e da imagem de textura, a qual também foi importada para o aplicativo IDRISI. Essas estatísticas proporcionaram a geração de gráficos que permitem melhor analisar as estatísticas computadas entre cada banda.

A partir das médias e dos desvios-padrão estimados dos dados de treinamento por classe (Figura 27), verifica-se que a imagem de textura, em geral, proporcionou as médias mais discrepantes e os maiores desvios-padrão, indicando maior variabilidade que as demais bandas. Esse fator é bastante positivo, visto que a variabilidade estatística introduzida por essa informação tende a auxiliar na discriminação das classes de cobertura, especialmente aquelas que possuem comportamento espectral similar.

Ao considerar as classes 1 (*Cerâmica*) e 9 (*Solo*), as quais proporcionam maior confusão na classificação usando abordagens convencionais, verifica-se que, com a inserção da imagem de textura, maior variabilidade estatística foi incorporada ao processo de classificação. Quando esse tipo de informação é desconsiderado, nota-se que as estatísticas são similares para as bandas fusionadas, dificultando a separabilidade. As classes mencionadas também apresentam similaridade com a classe 6 (*Outros*), mas, facilmente, o problema é solucionado o uso de informação textural.

Em relação às classes 2 (*Cobertura de fibrocimento*) e 5 (*Asfalto*), também com similaridade espectral, nota-se que tanto a imagem de textura quanto a banda 4 melhor contribuem para a discriminação entre ambas, com destaque para a variabilidade espectral proporcionada pela imagem de textura.

As demais classes são mais discrimináveis que as anteriores. A combinação da informação textural com a banda 1 é a que melhor auxilia a discriminação da classe 4 (*Concreto*), e as classes restantes (4 – *Cobertura metálica*, 10 – *Sombra*, 11 – *Curso d'água*, 12 – *Lagoa* e 13 – *Reservatório*) são mapeadas com maior sucesso principalmente através da junção da imagem de textura com a banda 2.






Figura 27: Médias e desvios-padrão dos dados de treinamento por classe estimados a partir das bandas fusionadas e da informação textural.

A etapa seguinte do processo de classificação consistiu na definição da arquitetura da rede, especificando-se uma rede multicamadas *feedforward*, a mais usual em



processamentos com imagens orbitais. Esse tipo de arquitetura pressupõe a definição de uma camada de entrada, de uma ou mais camadas escondidas e da camada de saída. Para tanto foram realizadas simulações com diferentes arquiteturas, com uma ou duas camadas escondidas, e verificado o desempenho da rede treinada com o algoritmo de aprendizagem *backpropagation*.

O número de nós da camada de entrada foi definido pela quantidade de dados de entrada, ou seja, as quatro bandas fusionadas e a imagem de textura, totalizando cinco nós. A camada de saída foi especificada por treze nós, que correspondem às treze classes de cobertura definidas no projeto de classificação. Além disso, foram selecionadas duas camadas escondidas, com vinte e cinco nós na primeira camada e dezoito na segunda, visto que a utilização de uma única camada não se mostrou suficiente para lidar com a variedade de classes, algumas das quais com menor separabilidade entre si. Dessa forma, a arquitetura considerada nessa aplicação foi 5-25-18-13 (Figura 28).

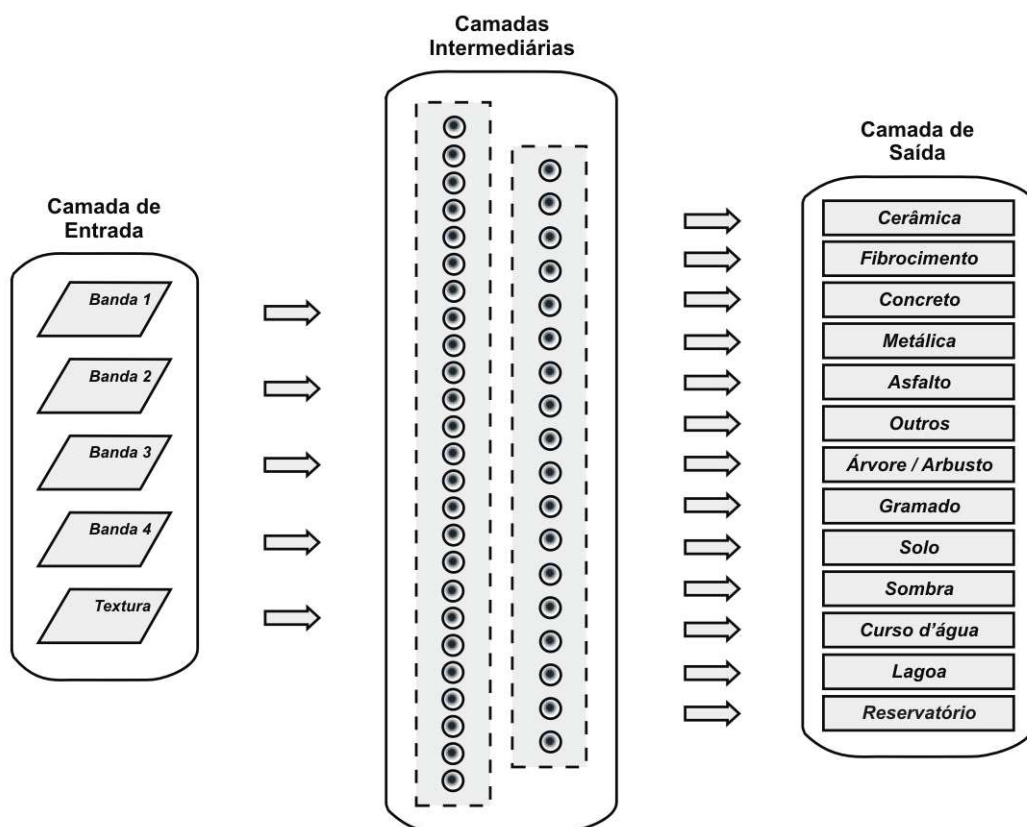


Figura 28: Arquitetura [5-25-18-13] selecionada para a aplicação da rede neural artificial.

O processo de treinamento supervisionado utilizando o algoritmo *backpropagation* implica na seleção prévia do conjunto amostras e na indicação do número de *pixels* de treinamento e validação a ser considerado para cada classe. Nesse caso, o valor

utilizado foi 600 *pixels* para cada conjunto de treinamento, em função da classe de menor representatividade na área de estudo. Deve-se destacar que o algoritmo utilizado, disponível no aplicativo IDRISI, não permite especificar qual será o conjunto de treinamento e qual será utilizado para validação. Simplesmente, coletam-se as amostras e indica-se a quantidade de *pixels* a ser considerada e, a partir disso, o algoritmo se encarrega de selecionar as amostras representativas de cada conjunto.

Além disso, foi necessário definir, previamente, os parâmetros de treinamento, os quais incluem a taxa de aprendizagem e o fator de impulso. Com relação à taxa de aprendizagem que, normalmente, correspondente à proporção do erro que é repassada aos nós a cada iteração, o valor considerado foi 0,001, que melhor se adaptou ao conjunto de dados. Para a definição do fator de impulso, que controla a velocidade de convergência da rede, foram testados valores entre 0,4 e 0,6, mas optou-se por utilizar o valor equivalente a 0,5, que proporcionou o melhor resultado para a rede.

Outras informações inseridas anteriormente à realização do treinamento da rede foram os critérios de parada. Esses critérios controlam quando o processo terminará e incluem três aspectos: o valor do erro médio quadrático (EMQ) mínimo aceitável; o número de iterações; e a taxa de “acurácia” desejada. Inicialmente, os valores *default* fornecidos pelo aplicativo foram mantidos, os quais correspondem a 0,0001, 10.000 e 100%, respectivamente para o EMQ, quantidade de iterações e acurácia, a fim de verificar o resultado proporcionado. Posteriormente, várias simulações foram realizadas, variando o número de iterações e analisando as estatísticas do treinamento, as quais incluem: valores dos erros de teste e validação; número de iterações; e taxa de “acurácia” computada a partir dos *pixels* de teste e validação coletados para as classes.

O processo de treinamento de uma rede neural artificial é iterativo em relação ao algoritmo de aprendizagem, que realiza o ajuste dos pesos da rede a cada iteração visando minimizar o EMQ. Por outro lado, é interativo em relação ao analista, que precisa realizar uma série de simulações até encontrar um resultado satisfatório para a classificação. Nessa aplicação, os melhores resultados corresponderam a 85,97% e 0,00045 para a “acurácia” e o EMQ do treinamento, respectivamente. Tais resultados foram obtidos após sucessivas simulações e considerando as seguintes especificações: arquitetura 5-25-18-13; taxa de aprendizagem equivalente a 0,001; fator de impulso igual a 0,5; e 7.000 iterações.

Após o treinamento da rede neural artificial, a classificação foi realizada. Nesse processo, além da saída convencional (rígida), na qual cada *pixel* é atribuído a uma



única classe, também foram produzidas imagens relativas para as classes temáticas, que expressam os graus de pertinência (ou níveis de ativação) dos *pixels* em relação a cada classe.

A etapa de pós-classificação, nesse caso, consistiu na aplicação do filtro da moda sobre a imagem classificada convencional, considerando uma janela 5x5, para minimizar a quantidade de *pixels* isolados dentro de regiões classificadas, assim como *pixels* localizados em regiões de bordas, ou seja, de transição entre classes, locais onde pode ocorrer grande quantidade de *pixels* erroneamente classificados.

Com isso, foi produzido o mapa da cobertura da terra da região selecionada da cidade de Presidente Prudente, considerando as subclasses definidas no nível III do sistema hierárquico de classificação em escala urbana. No Apêndice B, é apresentado o resultado do mapeamento temático realizado.

A partir do resultado do mapeamento pôde-se estimar as proporções de ocorrência de cada classe temática, as quais são listadas na Tabela 24, em metros quadrados ( $m^2$ ) e em porcentagem (%).

Tabela 24: Proporção de ocorrência estimada para as classes do mapeamento em escala urbana.

| Classe de cobertura       | Metros quadrados ( $m^2$ ) | Porcentagem (%) |
|---------------------------|----------------------------|-----------------|
| Cerâmica                  | 520831                     | 11,74           |
| Cobertura de fibrocimento | 160688                     | 3,62            |
| Concreto                  | 304272                     | 6,86            |
| Cobertura metálica        | 235483                     | 5,31            |
| Asfalto                   | 346585                     | 7,81            |
| Outros                    | 7341                       | 0,17            |
| Árvore / Arbusto          | 1263134                    | 28,47           |
| Gramado                   | 569430                     | 12,84           |
| Solo                      | 724613                     | 16,33           |
| Sombra                    | 141126                     | 3,18            |
| Curso d'água              | 105058                     | 2,37            |
| Lagoa                     | 1617                       | 0,04            |
| Reservatório              | 55906                      | 1,26            |
| Total                     | 4436084                    | 100             |

Para auxiliar no entendimento da análise posterior é apresentada a Figura 29, na qual foram destacados os principais pontos de referência do trecho selecionado da cidade de Presidente Prudente, os quais incluem: três avenidas (Ana Jacinta – acima à esquerda –, Washington Luiz – acima à direita – e Manoel Goulart – abaixo, de maior extensão); o curso d'água denominado Córrego do Veado; a área do campus da FCT/UNESP; parte do Parque do Povo; e o local da SEMEPP (Secretaria Municipal de Esportes de Presidente Prudente).







Figura 29: Localização dos principais pontos de referência do trecho selecionado da cidade de Presidente Prudente.

Conforme pôde ser observado na Tabela 24, a classe de maior representatividade espacial na área de estudo foi *Árvore / Arbusto*, com cerca de 28,47%. Essa alta proporção, pouco observada em ambientes urbanos, é decorrente do mapeamento ter sido realizado em uma região da cidade onde existem espaços abertos pouco edificados. Dentre esses espaços abertos está o campus da FCT/UNESP, que engloba vastas áreas verdes.

Como consequência da existência desses espaços abertos, as classes *Solo* e *Gramado* também representaram proporções significativas na área de estudo, correspondendo a 16,33% e 12,84%, respectivamente. As áreas de *Solo* indicaram os locais impactados, onde foi retirada a cobertura vegetal, totalmente ou mantendo apenas uma vegetação rala, para diferentes finalidades. Com relação à classe *Gramado*, esta foi representada, principalmente, pelo campus da FCT/UNESP e pela região pertencente à SEMEPP, onde existem áreas destinadas a fins esportivos, como campos de futebol, e também inclui o trecho mapeado do Parque do Povo, que é um dos principais pontos de lazer da cidade.

Os três tipos de cobertura descritos anteriormente, que pertencem ao grupo das classes ditas permeáveis (GALO; IMAI; ENNES, 2006), representam mais da metade da cobertura da área de estudo. Se forem adicionadas a esse valor as proporções de ocorrência das classes *Curso d'água*, *Lagoa* e *Reservatório*, respectivamente correspondentes a 2,37%, 0,04% e 1,26%, então um valor estimado superior a 60% de cobertura é obtido. A classe *Curso d'água*, que representa o menor percentual de ocorrência, é formada pelo trecho mapeado do Córrego do Veado, que está localizado na porção oeste da cidade de Presidente Prudente e que possui mais de 3 km de extensão. As demais classes, *Lagoa* e *Reservatório*, estão relacionadas, respectivamente, à lagoa situada no campus da FCT/UNESP, único corpo d'água natural da área mapeada, e às piscinas, principalmente, situadas na SEMEPP, FCT/UNESP e no condomínio mapeado, onde estas existem em grande proporção.

No que se refere às coberturas ditas impermeáveis, a classe *Cerâmica* foi a de maior percentual, equivalente a 11,74%, bem superior as demais. A proporção de destaque para esse tipo de cobertura em ambientes urbanos é esperada, visto que, geralmente, a maior parte das edificações urbanas possui telhado feito com esse material, principalmente em regiões onde reside a população de padrões sociais médio e alto.

As classes *Asfalto* e *Concreto* também representaram proporções significativas em relação às coberturas impermeáveis, com cerca de 7,81% e 6,86%, respectivamente. Todas as vias da área de estudo são asfaltadas, exceto trechos localizados no interior da FCT/UNESP, cobertos por *Solo*. A classe *Concreto* é predominante em calçadas e outros pavimentos, mas também recobre algumas edificações onde não existem telhados, mas sim laje exposta.

Edificações incluídas na classe *Cobertura metálica* corresponderam a 5,31% e estão situadas, principalmente, no entorno da Avenida Manoel Goulart, onde existem vários estabelecimentos comerciais, incluindo um *shopping center*. Essa avenida representa um dos principais corredores comerciais da cidade de Presidente Prudente. Em menor proporção, tal classe também ocorre ao redor das avenidas Washington Luiz e Ana Jacinta. Esses três trechos em destaque constituem locais de grande movimentação de veículos, que funcionam como eixos de ligação bairro-centro, conseqüentemente favorecendo a existência de um aglomerado comercial nessas regiões.

A classe *Cobertura de fibrocimento* corresponde a um tipo de cobertura mais popular e ocorre em menor proporção na área de estudo, em comparação com as demais classes impermeáveis mencionadas anteriormente, representando 3,62%. Edificações com tal



cobertura estão localizadas, em sua maioria, na FCT/UNESP, utilizadas como docentes e discentes, e também constituem estabelecimentos comerciais em algumas regiões da cidade.

A última cobertura impermeável mapeada foi representada pela classe *Outros*, com cerca de 0,17%. Essa menor proporção em relação às demais era esperada, visto que essa classe incluiu um tipo de cobertura pouco encontrado em áreas urbanas, isto é, borracha, utilizado para uma finalidade específica que, nesse caso, foi a pista de atletismo da FCT/UNESP.

Finalmente, a classe *Sombra*, característica de mapeamentos urbanos, representou, aproximadamente, 3,18%. A maior proporção dessa classe é decorrente dos nove edifícios existentes na área mapeada. Os trechos de vegetação de porte alto e as maiores edificações de uso comercial também proporcionam um índice significativo para essa classe.

### 6.5.3 Análise da confiabilidade do mapeamento

A análise da confiabilidade do mapeamento em escala regional foi realizada a partir dos coeficientes estatísticos e também usando medidas de incerteza, visto que a classificação pela rede neural artificial permitiu gerar saídas convencional e relativa. Para a análise da acurácia através dos índices estatísticos, o esquema de amostragem selecionado foi o aleatório estratificado e o número de elementos amostrais, considerando as Equações 16 e 17, foi estimado com valor da estatística qui-quadrado equivalente a  $\chi^2_{(1,0,98333)} = 5,730788$  (nível de confiança de 95%) e com precisão desejada ( $d_i$ ) de 5%. As proporções representativas de cada classe ( $p_i$ ) foram apresentadas na Tabela 24. Com isso foram estimadas 161 amostras, no mínimo, a serem definidas para as classes.

A unidade amostral utilizada foi um conjunto de  $3 \times 3$  *pixels* coletados para cada elemento amostral. Além disso, para obter a informação de “verdade terrestre” e gerar a imagem de referência foi realizado um trabalho de campo. Essa imagem de referência foi confrontada com o resultado final da classificação, utilizando o aplicativo IDRISI, originando a matriz de erros apresentada na Tabela 25:



Tabela 25: Matriz de erros gerada pela classificação em escala urbana.

|                 |     | Verdade Terrestre |     |     |     |     |     |     |     |     |    |    |    | $\Sigma x_{i+}$ |     |
|-----------------|-----|-------------------|-----|-----|-----|-----|-----|-----|-----|-----|----|----|----|-----------------|-----|
|                 |     | 1                 | 2   | 3   | 4   | 5   | 6   | 7   | 8   | 9   | 10 | 11 | 12 |                 | 13  |
| Classificação   | 1   | 145               | 0   | 5   | 0   | 0   | 0   | 0   | 0   | 49  | 0  | 0  | 0  | 0               | 199 |
|                 | 2   | 4                 | 55  | 2   | 0   | 9   | 0   | 0   | 0   | 0   | 0  | 0  | 0  | 0               | 70  |
|                 | 3   | 41                | 0   | 119 | 2   | 4   | 0   | 0   | 0   | 18  | 0  | 0  | 0  | 0               | 184 |
|                 | 4   | 0                 | 0   | 23  | 84  | 0   | 0   | 0   | 0   | 0   | 0  | 0  | 0  | 0               | 107 |
|                 | 5   | 0                 | 19  | 0   | 0   | 117 | 0   | 2   | 0   | 6   | 0  | 2  | 0  | 0               | 146 |
|                 | 6   | 0                 | 0   | 0   | 0   | 0   | 9   | 0   | 0   | 0   | 0  | 0  | 0  | 0               | 9   |
|                 | 7   | 0                 | 0   | 0   | 0   | 0   | 0   | 360 | 0   | 0   | 0  | 0  | 0  | 0               | 360 |
|                 | 8   | 0                 | 0   | 0   | 0   | 0   | 0   | 32  | 197 | 1   | 0  | 0  | 0  | 0               | 230 |
|                 | 9   | 12                | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 249 | 0  | 0  | 0  | 0               | 261 |
|                 | 10  | 0                 | 0   | 0   | 0   | 0   | 0   | 18  | 0   | 0   | 54 | 0  | 0  | 0               | 72  |
|                 | 11  | 0                 | 0   | 0   | 0   | 9   | 0   | 0   | 0   | 0   | 9  | 50 | 0  | 4               | 72  |
|                 | 12  | 0                 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0  | 0  | 9  | 0               | 9   |
|                 | 13  | 0                 | 0   | 0   | 1   | 0   | 0   | 0   | 0   | 0   | 0  | 0  | 0  | 53              | 54  |
| $\Sigma x_{+j}$ | 202 | 74                | 149 | 87  | 139 | 9   | 412 | 197 | 323 | 63  | 52 | 9  | 57 | 1773            |     |

onde: 1 = Cerâmica; 2 = Cobertura de fibrocimento; 3 = Concreto; 4 = Cobertura metálica; 5 = Asfalto; 6 = Outros; 7 = Árvore / Arbusto; 8 = Gramado; 9 = Solo; 10 = Sombra; 11 = Curso d'água; 12 = Lagoa; 13 = Reservatório.

A Tabela 25 indica que 1773 *pixels* foram coletados para a realização da análise da acurácia, o que corresponde a 197 amostras. Ou seja, foram selecionadas 36 unidades de amostragem além do mínimo necessário indicado pelas Equações 16 e 17. A partir disso verifica-se que, do total de *pixels* amostrados, 272 foram classificados erroneamente, isto é, cerca de 15,34% do total, o que proporcionou uma exatidão global ( $P_o$ ) de 84,66%.

Nesse caso, o valor obtido para a exatidão global não satisfaz a proposição de Anderson et al. (1976), que recomenda uma acurácia mínima de 85%. Contudo, isso não invalida o resultado, visto que o aumento da variabilidade espectral das classes, decorrente da melhora da resolução espacial do sensor, tende a dificultar a separabilidade entre as classes, diminuindo a acurácia da classificação.

Os demais indicadores da exatidão global da classificação, as estatísticas *Tau* ( $\tau$ ) e *Kappa* ( $\hat{\kappa}$ ), também foram calculados. Os valores obtidos para esses coeficientes foram 83,38% e 82,47%, respectivamente. O gráfico da Figura 30 mostra os percentuais de concordância obtidos para os três índices globais computados a partir da matriz de erros. Novamente observa-se que a exatidão global tende a superestimar o resultado da classificação, por considerar apenas o percentual de elementos corretamente classificados, enquanto os coeficientes *Tau* e *Kappa* fornecem valores com maior consistência por

considerarem também o percentual de concordância por casualidade, para o cálculo do valor final.




Figura 30: Percentuais de concordância computados para os índices totais de acurácia da classificação em escala urbana.

Como não é suficiente analisar apenas a acurácia total do mapeamento, visto que as classes proporcionam valores de acurácia distintos, índices estatísticos também podem ser computados por classe. Para tanto foram calculadas a exatidão do usuário ( $EU$ ) e do produtor ( $EP$ ), as quais refletem os erros de inclusão ( $E_I$ ) e de exclusão ( $E_E$ ), respectivamente, bem como foi calculada a concordância  $Kappa$  por classe. Os valores desses coeficientes são listados na Tabela 26.

Tabela 26: Índices de exatidão por classe computados para o mapeamento em escala urbana.

| Classes de cobertura      | $EU$ (%) | $E_I$ (%) | $EP$ (%) | $E_E$ (%) | $\hat{\kappa}_i$ (%) |
|---------------------------|----------|-----------|----------|-----------|----------------------|
| Cerâmica                  | 72,86    | 27,14     | 71,78    | 28,22     | 69,38                |
| Cobertura de fibrocimento | 78,57    | 21,43     | 74,32    | 25,68     | 77,64                |
| Concreto                  | 64,67    | 35,33     | 79,87    | 20,13     | 61,43                |
| Cobertura metálica        | 78,50    | 21,50     | 96,55    | 3,45      | 77,40                |
| Asfalto                   | 80,14    | 19,86     | 84,17    | 15,83     | 78,45                |
| Outros                    | 100,00   | 0         | 100,00   | 0         | 100,00               |
| Árvore / Arbusto          | 100,00   | 0         | 87,38    | 12,62     | 100,00               |
| Gramado                   | 85,65    | 14,35     | 100,00   | 0         | 83,86                |
| Solo                      | 95,40    | 4,60      | 77,09    | 22,91     | 94,38                |
| Sombra                    | 75,00    | 25,00     | 85,71    | 14,29     | 74,08                |
| Curso d'água              | 69,44    | 30,56     | 96,15    | 3,85      | 68,52                |
| Lagoa                     | 100,00   | 0         | 100,00   | 0         | 100,00               |
| Reservatório              | 98,15    | 1,85      | 92,98    | 7,02      | 98,09                |

Conforme a Tabela 26, as classes *Outros*, *Árvore / Arbusto* e *Lagoa* foram as que apresentaram maiores índices de exatidão do usuário, com nenhum *pixel* incluído

erroneamente nessas classes, dentre o conjunto total de *pixels* amostrados. As classes *Outros* e *Lagoa* representaram as menores proporções de ocorrência na área de estudo e não ofereceram dificuldade de discriminação a partir do conjunto de dados utilizados. Além disso, a classe *Árvore / Arbusto* também foi facilmente discriminada com a possibilidade de uso da banda 4 fusionada. Por outro lado, a classe *Concreto* proporcionou o menor índice de exatidão do usuário, visto que esta apresentou padrões de resposta espectral similares a diferentes classes, resultando em maior confusão na classificação.

Os maiores índices de exatidão do produtor foram obtidos, novamente, para as classes *Outros* e *Lagoa*, assim como para a classe *Gramado*, devido à incorporação da banda 4 na classificação. Ao contrário, a classe *Cerâmica* proporcionou o menor valor de exatidão do produtor ocasionado pela mistura com os tipos de cobertura *Concreto* e *Solo*, principalmente.

A partir da análise do índice de concordância *Kappa* por classe, cujos valores são próximos aos obtidos para a exatidão do usuário, verifica-se que o pior resultado foi calculado para a classe *Concreto*, que mais se confundiu com outras classes, seguida pelas classes *Curso d'água* e *Cerâmica*. Esse índice é o que melhor indica a confusão entre classes e, conseqüentemente, o que melhor reflete a acurácia de cada classe individualmente, visto que o mesmo é computado considerando tanto os valores corretamente classificados, quanto realizando uma ponderação entre os erros de inclusão e de exclusão.

Dessa forma, verifica-se que a classificação utilizando a técnica por rede neural, para mapeamento em escala urbana, forneceu bons resultados de acurácia e minimizou a confusão entre as classes que possuem similaridade espectral entre si. Particularmente em relação às classes *Cerâmica* e *Solo* e também *Cobertura de fibrocimento* e *Asfalto*, as quais indicaram, previamente, maior dificuldade de discriminação pelos classificadores convencionais, nota-se que essa abordagem permitiu lidar com esse tipo de dificuldade e mostrou ser uma alternativa para melhor discriminar classes, não apenas em escala regional, onde essa técnica é bastante utilizada, mas também para mapeamentos em escala urbana.

As medidas de incerteza do mapeamento geradas pela classificação pela rede neural artificial são obtidas a partir das imagens relativas que expressam os níveis de ativação de saída para cada *pixel* em relação a cada classe. Quanto maior o nível de ativação, isto é, o grau de pertinência, menor a incerteza para um dado *pixel*. Na Figura 31 são apresentadas as imagens relativas fornecidas para as classes *Outros* (A) e *Árvore / Arbusto* (B). Conforme a escala de tons de cinza, no caso da imagem A, verifica-se a alta pertinência dos *pixels* no local destinado à pista de atletismo da FCT/UNESP, a qual é a única região da



área de estudo revestida por esse tipo de cobertura. Em relação à imagem B, nota-se a alta pertinência para a classe *Árvore / Arbusto* em boa parte da área de estudo.

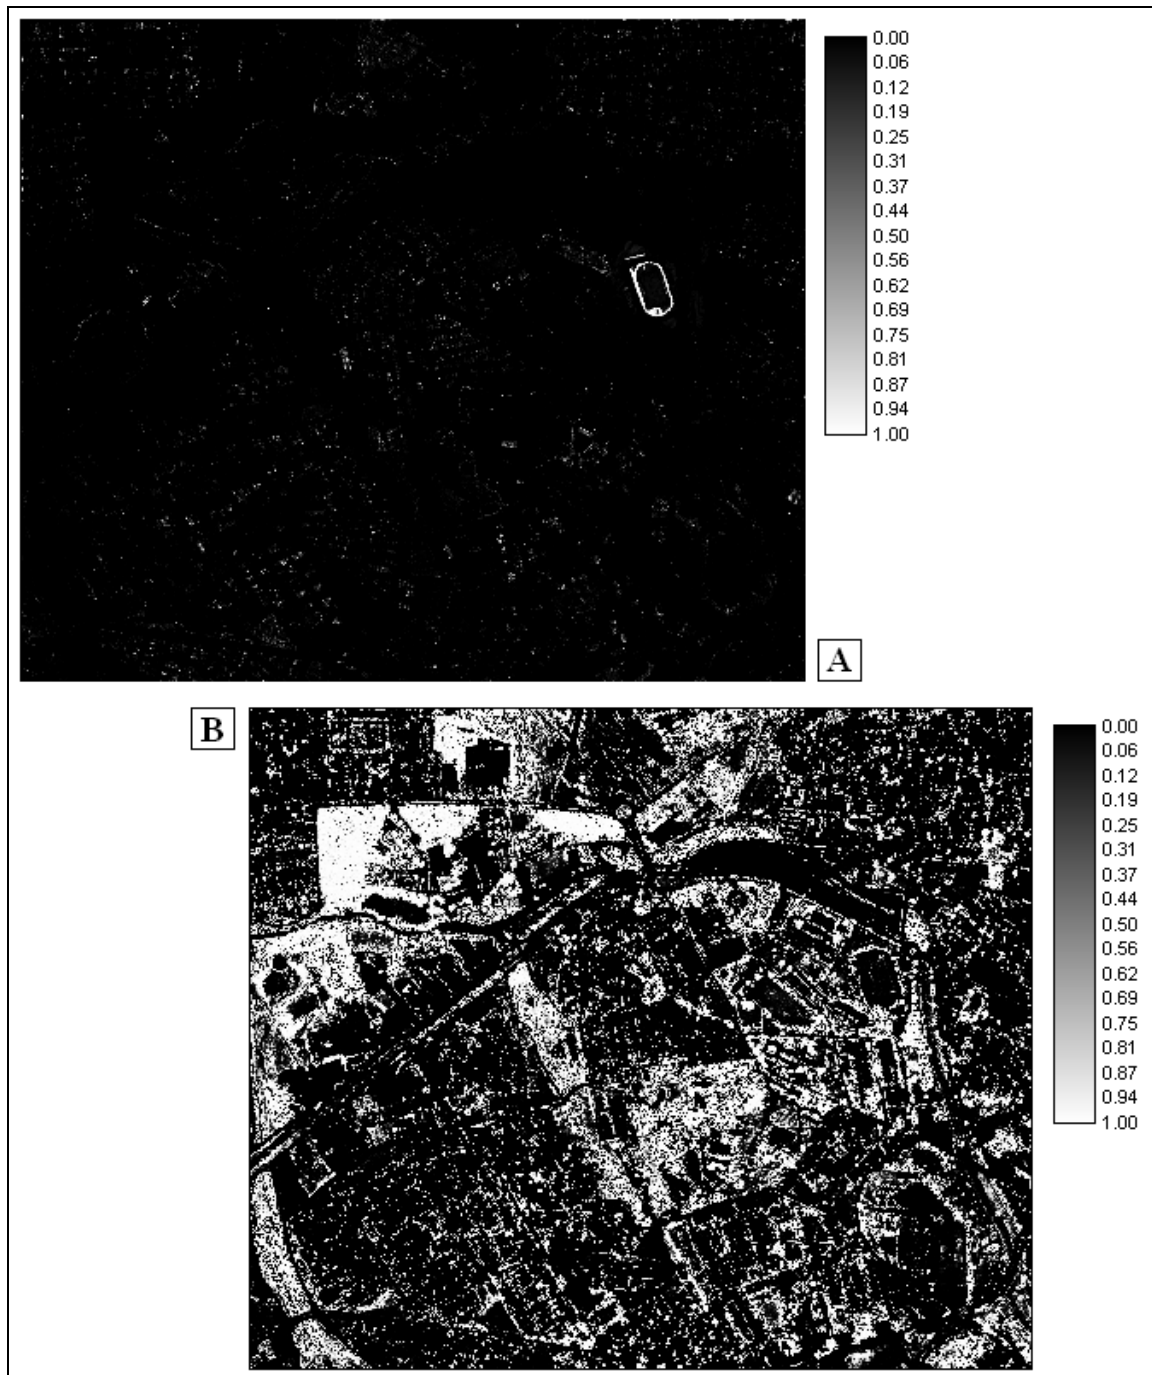


Figura 31: Imagens relativas que expressam os graus de pertinência para as classes *Outros* (A) e *Árvore / Arbusto* (B).

Ao considerar, novamente, as classes *Outros* (A) e *Árvore / Arbusto* (B), as imagens de incerteza foram computadas a partir da Equação 25 (item 3.3.2) e são apresentadas na Figura 32. Como a incerteza é o complemento da probabilidade, verifica-se



que os *pixels* com alto grau de pertinência (Figura 31) apresentam, conseqüentemente, nenhuma ou quase nenhuma incerteza ao serem atribuídos às classes consideradas. Isso mostra que o classificador não encontrou maiores dificuldades ao classificar os *pixels* pertencentes a tais classes, como foi comprovado ao analisar os coeficientes estatísticos que indicaram alta acurácia para essas classes.

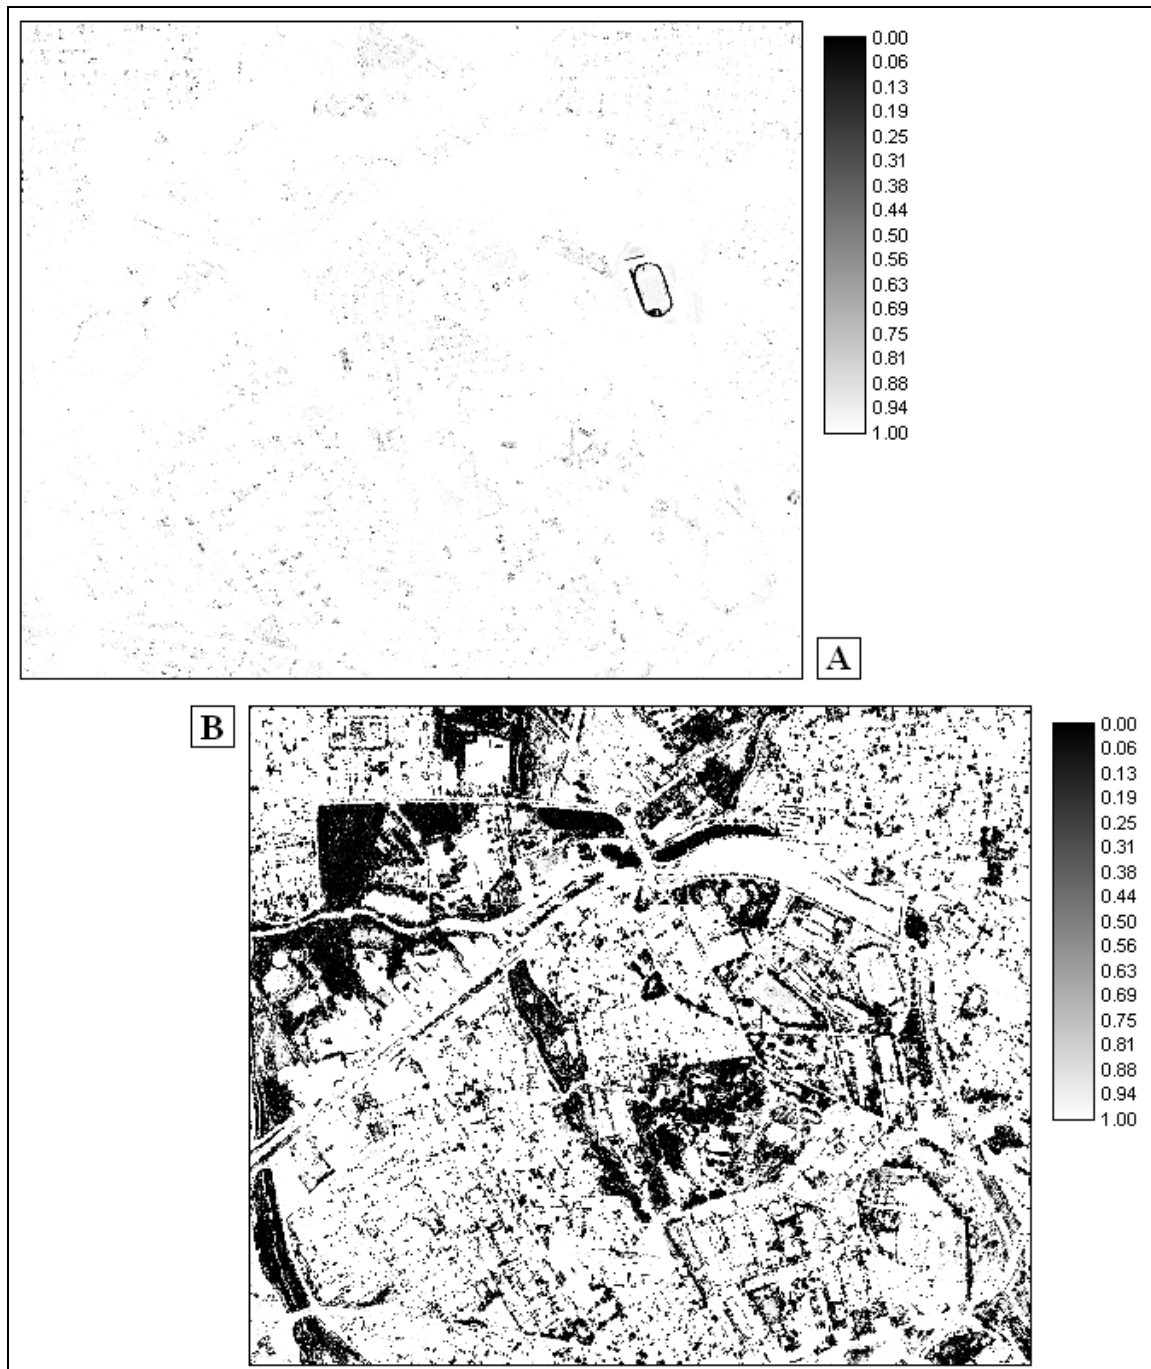


Figura 32: Imagens de incerteza para as classes Outros (A) e Árvore / Arbusto (B), mapeadas pelo classificador por rede neural artificial.



Embora já tenha sido constatada a relevância da imagem de textura no processo de classificação, o mesmo também pode ser observado através das saídas relativas. Ao considerar a classe *Cerâmica*, por exemplo, que tende a se confundir com a classe *Solo*, em um processo de classificação baseado apenas na informação espectral, os *pixels* pertencentes a ambas as classes apresentam graus de pertinência próximos e ocasionam incerteza no processo de decisão. Isso foi verificado ao aplicar a rede neural artificial apenas com as bandas fusionadas, desconsiderando a informação textural. A Figura 33 permite comparar as imagens relativas geradas quando a classificação foi testada sem a informação de textura (A) e com o uso dessa informação (B). As áreas circuladas na imagem A correspondem à classe *Solo* e a seta indica edificações com cobertura de *Cerâmica*, em sua maioria. Primeiro, percebe-se que tanto áreas de *Solo* quanto de *Cerâmica* apresentam pertinências próximas (imagem A), que só são diferenciadas quando as medidas de entropia auxiliam o classificador (imagem B).



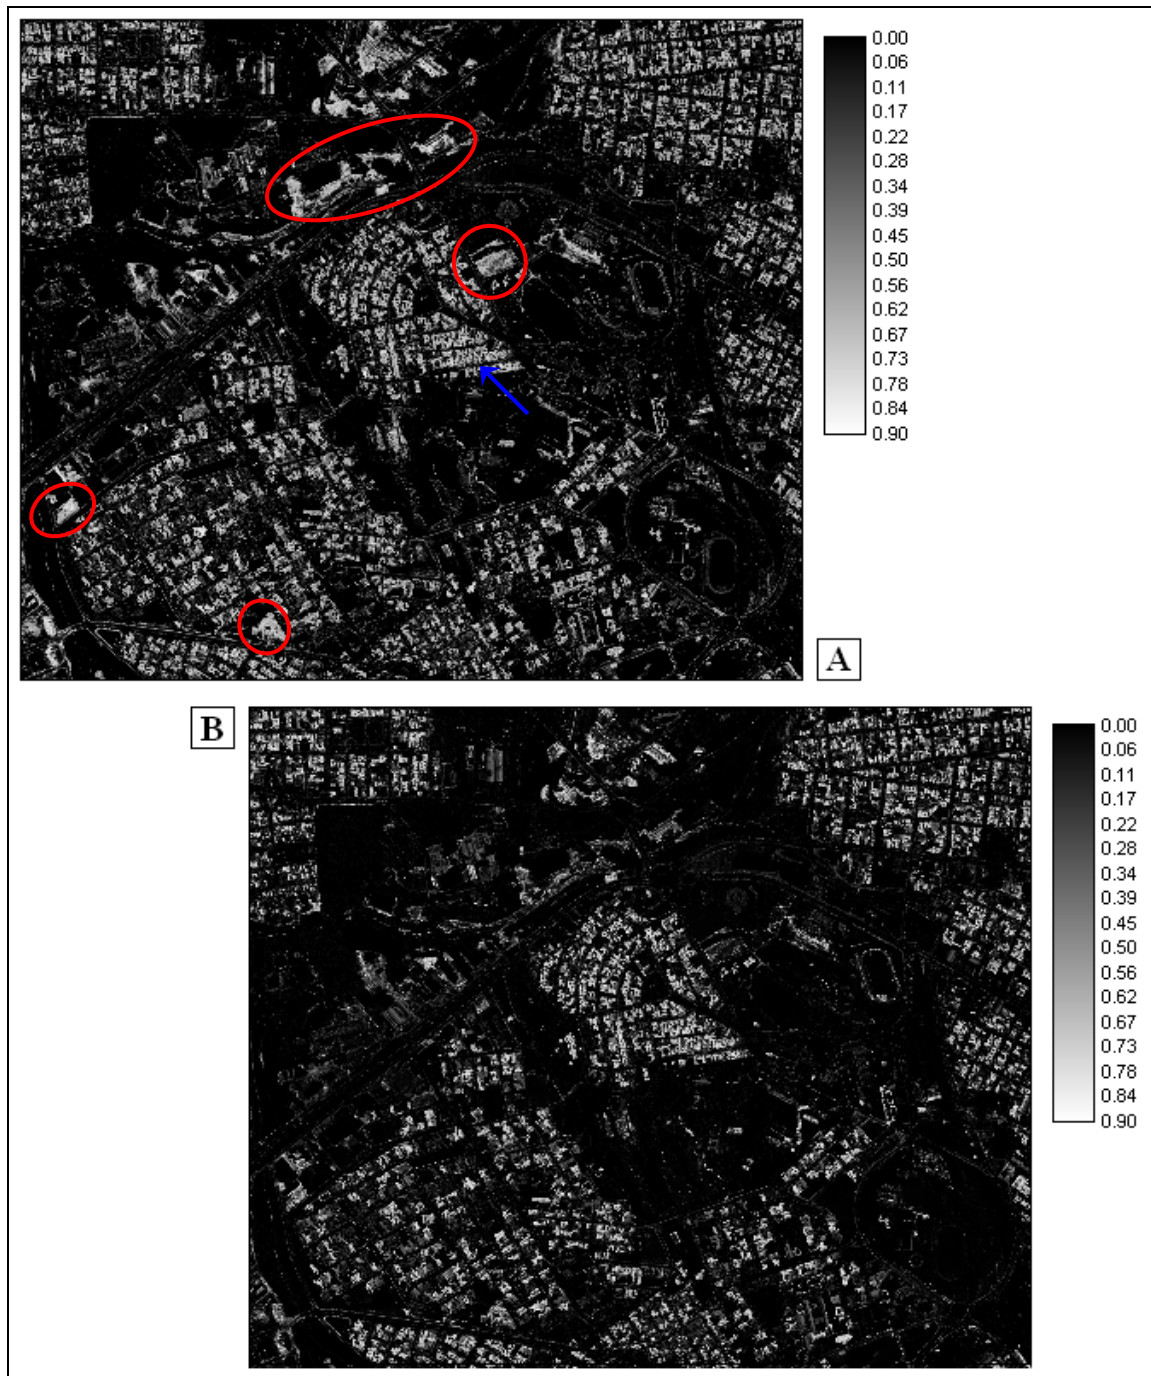


Figura 33: Saídas relativas para a classe Cerâmica, sem a informação de textura (A) e com o uso dessa informação (B).

Uma única imagem de incerteza também foi produzida a partir das saídas relativas fornecidas pelo classificador. Essa imagem foi gerada considerando a Equação 28 (item 6.4.3) e foi fatiada em cinco intervalos: (i) 0.0 – 0.2; (ii) 0.2 – 0.4; (iii) 0.4 – 0.6; (iv) 0.6 – 0.8; e (v) 0.8 – 1.0 (Figura 34). Como pode ser observado, a maior proporção da área de estudo apresentou incerteza variando entre 0.0 e 0.2. Em geral, essas áreas corresponderam às classes que proporcionaram maior acurácia no mapeamento, sendo

facilmente discrimináveis através do conjunto de dados, as quais incluem *Árvore / Arbusto*, *Gramado* e *Outros*, por exemplo. Além disso, as proporções de incerteza entre 0.2 – 0.4 e 0.4 – 0.6 também foram significativas no resultado do mapeamento, sendo geradas pelas classes que proporcionaram maior confusão como, por exemplo, *Cerâmica* e *Solo*.

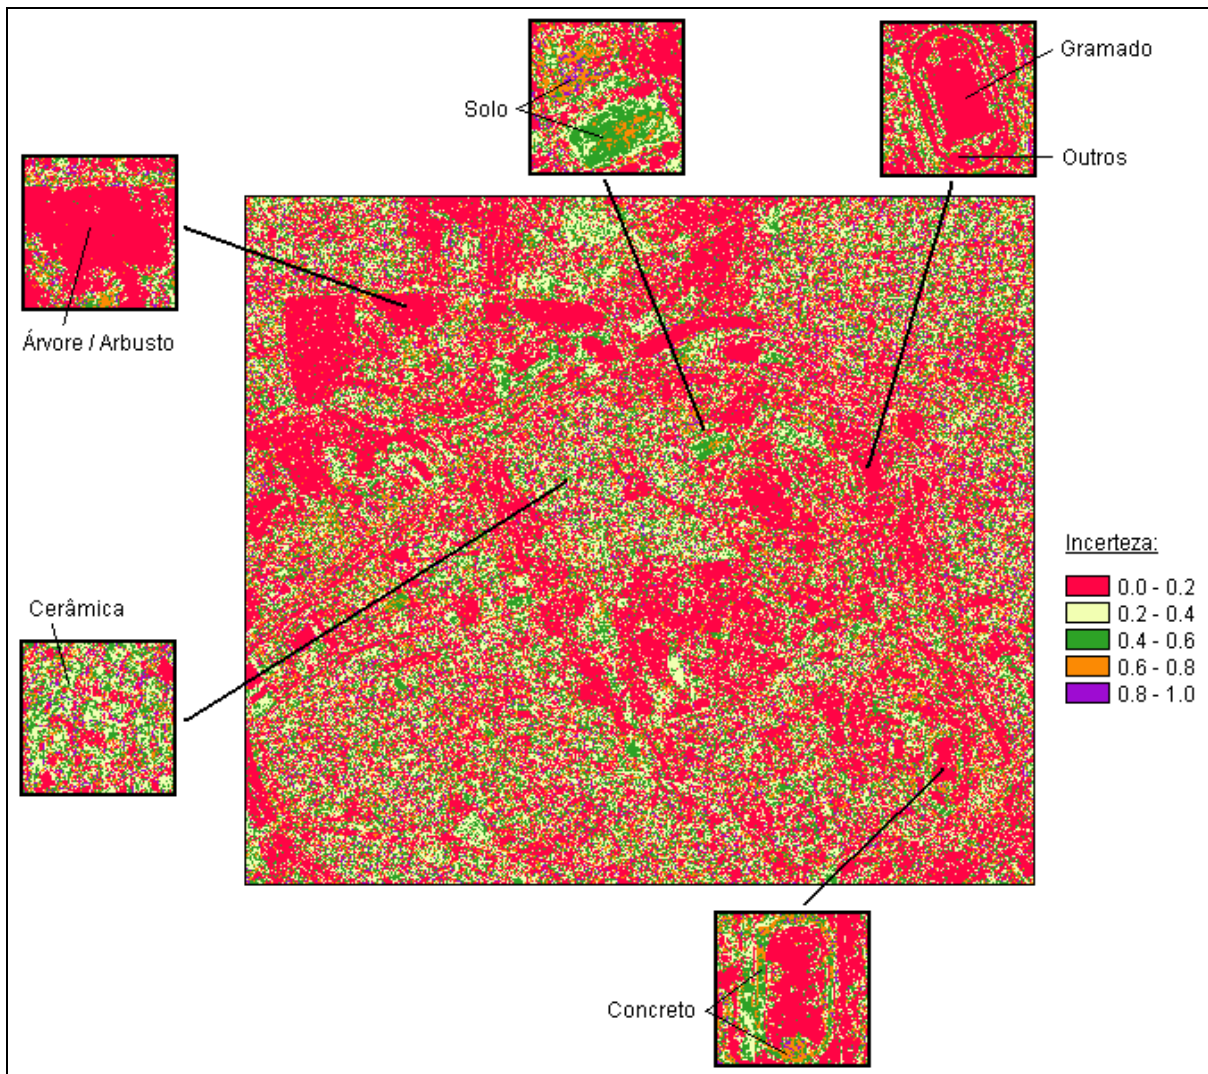


Figura 34: Imagem de incerteza gerada a partir das saídas relativas fornecidas pela classificação pela rede neural artificial.

#### 6.5.4 Adequação das classes de cobertura propostas a classes de uso da terra

Como já mencionado nesta pesquisa, é preciso ter ciência de que existe distinção entre o que é cobertura e o que é uso da terra. Duas parcelas de terra podem ter usos similares, mas coberturas diferentes. Por exemplo, um campo de golfe e um supermercado

representam usos comerciais, contudo, o primeiro é desenvolvido em uma área coberta por grama, enquanto o último é considerado um tipo de edificação, provavelmente, com cobertura metálica. Do mesmo modo, parcelas com tipos de cobertura semelhantes podem ter usos distintos. Por exemplo, aquela área revestida por grama e utilizada para a prática de golfe pode se assemelhar a outra área verde usada para o lazer (ex.: parque).

Mudanças no uso da terra, assim como na cobertura, causam impacto tanto na qualidade ambiental quanto na qualidade de vida das pessoas e representam dois aspectos diretamente relacionados ao bem-estar humano. Dessa maneira, as atividades desenvolvidas pelas pessoas em cada local de uma cidade e que caracterizam o seu uso também podem ser informações úteis a tomadas de decisão.

Assim como mapeamentos temáticos são utilizados para gerar mapas de cobertura da terra derivados de imagens orbitais, essa metodologia também permite a identificação e a representação do uso da terra. Contudo, este é um procedimento que implica em maior dificuldade, visto que, geralmente, informações sobre o tipo de uso não podem ser extraídas apenas com base no que se observa em uma imagem. Melhor dizendo, se por um lado é possível concluir que uma determinada edificação possui telhado de cerâmica, simplesmente ao analisar a resposta espectral fornecida pelo alvo, não se pode ter certeza sobre o tipo de uso daquela edificação sem a constatação em campo, e muito menos pode-se afirmar que em todas as edificações com telhado de cerâmica mapeadas são desenvolvidas as mesmas atividades. Dessa forma, pesquisas de campo são necessárias de modo a definir os padrões de uso predominantes em cada parcela da área de estudo.

Para o mapeamento do uso da terra, visto que somente informação espectral (ou mesmo espacial) é insuficiente, regras de classificação normalmente são utilizadas para associar os *pixels* às classes. Nesse sentido, o processo de classificação, muitas vezes, é desenvolvido em três estágios, conforme destacam Donnay, Barnsley e Longley<sup>29</sup> (2004 apud LIZARAZO, 2006), e o uso da terra é derivado a partir de classes de cobertura, com base em métricas espaciais. Herold, Liu e Clarke (2003) utilizaram tanto métricas espaciais quanto informações de textura de co-ocorrência para mapear o uso da terra e constataram que ambas contribuíram para a discriminação dos tipos de uso.

Os objetivos desta pesquisa não incluem a classificação do uso da terra. O que será apresentado aqui é apenas uma adequação das classes de cobertura, propostas na

---

<sup>29</sup> DONNAY, J. P.; BARNSELY, M. J.; LONGLEY, P. A. Remote sensing and urban analysis. In: DONNAY, J. P.; BARNSELY, M. J.; LONGLEY, P. A. **Remote sensing and urban analysis**. London: Taylor & Francis, 2000.



Tabela 15, a classes de uso da terra, baseada, principalmente, nos sistemas de classificação apresentados no item 4. Outras referências consultadas foram: Whittier College (1997); DNR (1990); Michel e Heyman (1993); e MEOEA (1992).

A proposição feita para descrever as classes de uso da terra em escala urbana é apresentada na Tabela 27, considerando dois níveis de detalhamento. O nível I inclui quatro classes de cobertura abrangentes (as mesmas propostas na Tabela 15), a partir das quais foram subdivididas vinte e quatro classes de uso no nível II.

Tabela 27: Sistema hierárquico de classificação para o mapeamento do uso da terra em escala urbana.

| NÍVEL I                               | NÍVEL II   |
|---------------------------------------|--|
| 1 Área construída                     | 1.1 Residencial<br>1.2 Comercial e serviços<br>1.3 Industrial<br>1.4 Institucional<br>1.5 Transporte, comunicação e utilitários<br>1.6 Militar<br>1.7 Uso misto                                    |
| 2 Área vegetada                       | 2.1 Preservação e proteção ambiental<br>2.2 Espaço aberto e recreação<br>2.3 Pecuária<br>2.4 Cultivo agrícola<br>2.5 Extrativismo animal<br>2.6 Extrativismo vegetal                               |
| 3 Área não construída ou não vegetada | 3.1 Área de mineração<br>3.2 Área de depósito de lixo/entulho<br>3.3 Área de construção<br>3.4 Área desocupada ou sem uso definido   |
| 4 Água                                | 4.1 Aqüicultura <sup>30</sup><br>4.2 Pesca<br>4.3 Geração de energia<br>4.4 Transporte<br>4.5 Lazer e desporto<br>4.6 Captação e/ou tratamento de água<br>4.7 Recepção e/ou tratamento de efluente |

A partir do nível II do sistema pode ser derivado um terceiro nível mais detalhado e que, conseqüentemente, exigirá o uso de novas regras de discriminação de classes. A partir da classe *Residencial*, por exemplo, é comum a caracterização do uso em baixa, média e alta densidades, com base no tamanho do lote, na taxa de ocupação, dentre outros fatores. Essa subdivisão é considerada, por exemplo, na Carta de Zoneamento Urbano de Presidente Prudente, conforme Sabo (2006).

<sup>30</sup> Aqüicultura é o cultivo de organismos aquáticos – peixes, moluscos, crustáceos, rãs e algas – em água doce ou salgada para alimentação humana e finalidades industriais ou experimentais (ACIESP, 1997).





## 7 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES

### 7.1 Considerações finais

A ausência de um sistema de classificação voltado para o mapeamento da cobertura da terra do território brasileiro foi um dos principais motivadores desta pesquisa, juntamente com a escassez de propostas teóricas existentes na literatura. O que se tem disponível é uma gama de sistemas propostos em diversos países que são específicos a determinadas necessidades de mapeamento, com poucas exceções e que não possibilitam a descrição da variedade de tipos de cobertura existentes.

Nesse contexto, o sistema proposto busca contribuir para uma futura padronização de classes de cobertura da terra, não apenas da nomenclatura, mas também dos critérios utilizados para descrevê-las. Isso poderá favorecer o intercâmbio de informações, bem como atualizações periódicas visto que, se a nomenclatura das classes e suas descrições são padronizadas, o risco da utilização de critérios distintos para os mapeamentos será minimizado.

Deve-se destacar também que o sistema proposto é útil a diversas aplicações e usuários por apresentar uma ampla variedade de classes dispostas em diferentes níveis hierárquicos de detalhamento. Conforme a necessidade do mapeamento, maior ou menor grau de detalhamento pode ser requerido, podendo-se optar por qualquer um dos níveis de detalhe propostos ou mesmo especificar outros níveis mais detalhados, por se tratar de um sistema flexível à incorporação de novas categorias.

Além de propor o sistema hierárquico de classificação, o mesmo também foi testado a partir da definição de um estudo de caso, tanto em escala regional quanto urbana, e foi possível constatar que o sistema supriu plenamente as necessidades dos mapeamentos. Além disso, a elaboração de um projeto de classificação adequado foi fundamental para evitar inconsistências nos processos de mapeamento, destacando as alternativas mais adequadas e viáveis referentes aos tipos de dados e técnicas de extração de informação para as escalas regional e urbana.

Particularmente em relação à aplicação em escala regional, o uso da técnica de classificação baseada em abordagem *fuzzy* permitiu lidar melhor com a existência de *pixels* mistos na imagem orbital, decorrente da resolução espacial média do sensor. Essa é uma



abordagem ainda pouco usual em mapeamentos temáticos, mas que, além de fornecer resultados mais adequados, também proporcionou a análise da incerteza incorporada ao processo de mapeamento, identificando as áreas com maior probabilidade de erro no processo de atribuição dos *pixels* às classes, informação que pode ser útil tanto ao analista quanto ao futuro usuário do mapa classificado.

No contexto do mapeamento em escala urbana, a classificação por rede neural artificial representou uma boa alternativa para lidar com a extração de informações a partir de imagens de resolução espacial centimétrica. Essa técnica de classificação se mostrou mais satisfatória que o uso de classificadores convencionais, por permitir incorporar outras informações ao processo de decisão além da espectral, e forneceu bons resultados. Desse modo, embora alguns pesquisadores enfatizem a necessidade do uso da classificação orientada a objeto para mapeamentos em escala urbana, outras técnicas de classificação também podem oferecer soluções eficientes aos objetivos pretendidos, sendo, portanto, essencial investigar o potencial de diferentes técnicas, ao invés de restringir o uso de uma única abordagem.

Como em qualquer processo de geração de informação, nesse caso, de característica temática, esta pesquisa também evidenciou a importância de analisar a qualidade do produto gerado, principalmente por se tratar de um tipo de informação que poderá ser útil ao processo de tomada de decisão. Por esse motivo, quanto mais fiel à realidade for o produto cartográfico, maior segurança os planejadores terão para tomar suas decisões amparados por esse tipo de informação.

Diante disso, esta pesquisa também contribuiu no sentido de reafirmar uma metodologia para o desenvolvimento de mapas temáticos, desde a seleção e aquisição dos dados necessários, até o tratamento e o processamento desses dados e a posterior análise da qualidade da informação produzida. Essas são etapas cruciais, sem as quais é inviável atender a qualquer objetivo de mapeamento.

Finalmente, pretendeu-se tornar clara a distinção entre informações de uso e de cobertura da terra, visto que constantemente se observa na literatura uma confusão nesse sentido. É importante saber distinguir qual o tipo de informação que se pretende mapear (uso e/ou cobertura), a fim de que não haja inconsistência entre os objetivos do mapeamento e as classes de interesse previstas no projeto de classificação. Caso contrário, isso pode demandar aumento de custo e de tempo para fazer as adequações necessárias.

Como conclusão final, constata-se que os objetivos propostos nesta pesquisa foram alcançados no que se refere à proposição de um sistema hierárquico amplo e



abrangente que pode ser aplicado a diferentes escalas e níveis de detalhamento. O estudo de caso possibilitou testar um conjunto do total de classes propostas no sistema e, de modo geral, espera-se que os resultados alcançados possam servir como fonte de informação útil a outros pesquisadores e que as proposições feitas neste estudo sejam futuramente testadas e avaliadas em outros trabalhos.

## 7.2 Recomendações

Devido à natureza abrangente da pesquisa desenvolvida, diferentes perspectivas de trabalhos futuros podem ser exploradas. Em relação ao sistema hierárquico proposto, particularmente para o mapeamento em escala regional, este precisa ser amplamente testado, em diferentes regiões, de forma a permitir avaliar o conjunto total de classes e averiguar a existência de inconsistências ou mesmo sugerir outras classes que possam ser incorporadas ao sistema e que não foram previstas nesta pesquisa. Como o território brasileiro abrange uma vasta extensão territorial, essa realidade dificulta, consideravelmente, a proposição de qualquer sistema voltado para o mapeamento do país e inviabilizou testá-lo por completo. Por isso, espera-se que esse sistema, de fato, sirva como um referencial teórico e que seja aplicado e testado em outras áreas de interesse.

No que se refere ao sistema hierárquico para mapeamento urbano, este também foi proposto de maneira ampla, contendo uma variedade de classes. Assim, muito embora classes utilizadas para esse nível de detalhamento, normalmente, se refiram a proposições específicas a cada aplicação, também seria viável testar esse sistema no mapeamento de outras áreas de estudo podendo, assim, expandir a hierarquia proposta, ou mesmo fazer adequações a partir das classes previstas no sistema.

O uso da teoria de conjuntos *fuzzy* em mapeamentos temáticos é outro assunto que requer pesquisas, visto que se trata de uma teoria matemática recentemente incorporada a essa área. Especificamente em relação à classificação relativa bayesiana, algum estudo pode ser feito no sentido de avaliar a melhor maneira de ponderar os pesos da matriz de partição *fuzzy*, que representa a maior dificuldade na execução dessa técnica. Além disso, existem outras técnicas de classificação *fuzzy* descritas na literatura que podem ser exploradas, implementadas e disponibilizadas à comunidade usuária, como, por exemplo, a classificação





baseada no algoritmo *fuzzy c*-médias, que foi testada em diferentes referências consultadas sobre o tema.

Pesquisas na área de mapeamento urbano merecem destaque nas recomendações feitas nesta pesquisa, diante da tendência para o lançamento de novos satélites de sensoriamento remoto que produzirão imagens de resolução espacial melhorada, além daqueles já existentes. Agrega-se a isso a dificuldade de mapeamentos nessa escala, diante da complexidade urbana e da impossibilidade do tratamento adequado desse tipo de informação a partir das técnicas convencionais de classificação. Nesse sentido, além da realização de outros estudos que incorporem medidas de textura, informação de contexto ou ainda dados auxiliares, também seria importante testar a classificação orientada a objeto para a hierarquia proposta, se possível, para a mesma área de estudo, a fim de comparar e avaliar os resultados alcançados, identificando as vantagens advindas de cada técnica.

Com relação à análise da qualidade temática dos mapeamentos, é perceptível que, até o momento, a maioria dos pesquisadores tem utilizado, basicamente, o que está descrito nesta pesquisa. Contudo, nem todas as considerações são as mais adequadas para qualificar mapas gerados a partir de imagens orbitais e, por isso, requerem esforços no sentido de aprimorá-las, como a proposição de Landis e Koch (1977), por exemplo. Uma outra sugestão de pesquisa é em relação à derivação da matriz de erros *fuzzy*, feita a partir de uma classificação *fuzzy* e de dados de referência *fuzzy*. Embora nesta pesquisa tenha sido considerada uma matriz de erros convencional, existem recomendações na literatura no sentido de que a matriz de erros *fuzzy* é a que melhor se adequa à avaliação de uma classificação *fuzzy*, e foi utilizada, por exemplo, no trabalho de ISLAM (2004), dentre outros consultados.



## REFERÊNCIAS

ACIESP – ACADEMIA DE CIÊNCIAS DO ESTADO DE SÃO PAULO. **Glossário de ecologia**. 2. ed. São Paulo: ACIESP, 1997.

AMORIM, M. C. C. T. **O clima urbano de Presidente Prudente/SP**. 2000. 374 f. Tese (Doutorado em Geografia Física) – Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo.

ANDERSON, J. R. et al. **A land use and land cover classification system for use with remote sensor data**. Geological Survey Professional Paper 964. Washington: USGS, 1976.

ANDRADE, A. F.; BOTELHO, M. F.; CENTENO, J. A. S. Classificação de imagens de alta resolução integrando variáveis espectrais e forma utilizando redes neurais artificiais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11, 2003, Belo Horizonte, Brasil. **Anais...** Belo Horizonte: INPE, 2003. p. 265-272.

ARAÚJO, E. H. G.; KUX, H. J. H.; FLORENZANO, T. G. Análise multitemporal de dois bairros de Belo Horizonte (MG) usando classificação orientada a objetos de imagens QuickBird e inferências espaciais. In: BLASCHKE, T; KUX, H. **Sensoriamento remoto e SIG avançados**. 2. ed. São Paulo: Oficina de Textos, 2007.

ARONOFF, S. **Remote sensing for GIS managers**. Redlands: ESRI Press, 2005.

ART, H. W. **Dicionário de ecologia e ciências ambientais**. São Paulo: Companhia Melhoramentos, 1998.

BITTENCOURT, G. **Inteligência computacional**. Florianópolis: UFSC, 2000.

BLASCHKE, T. Object-based contextual image classification built on image segmentation. In: ADVANCES IN TECHNIQUES FOR ANALYSIS OF REMOTELY SENSED DATA, 2003. **Proceedings...** IEEE, 2004. p. 113-119.

BOSSARD, M.; FERANEC, J.; OTAHEL, J. **CORINE land cover technical guide – addendum 2000**. Technical report n. 40. Copenhagen: EEA, 2000.



BRASIL. Resolução nº 909, de 8 de agosto de 2001. Aprova da NBC T 10 - dos aspectos contábeis específicos em entidades diversas, o item: NBC T 10.4 - Entidades Agropecuárias. **Diário Oficial da União**, Brasília, 2001.

BURROUGH, P. A.; VAN GAANS, P. F. M.; HOOTSMANS, R. Continuous classification in soil survey: spatial correlation, confusion and boundaries. **Geoderma**, v. 77, p. 115-135, 1997.

BÜTTNER, G. et al. The CORINE land cover 2000 project. **EARSel eProceedings**, v. 3, n. 3, p. 331-346, 2004. Disponível em: <<http://www.eproceedings.org/>>. Acesso em: 12 jan. 2008.

\_\_\_\_\_. **Corine land cover update 2000: technical guidelines**. Technical report. Copenhagen: EEA, 2002. Disponível em: <<http://reports.eea.eu.int>>. Acesso em: 13 jan. 2008.

CAETANO, M.; MATA, F.; FREIRE, S. Accuracy assessment of the portuguese CORINE land cover map. In: MARÇAL, A. **Global developments in environmental earth observation from space**. Rotterdam: Millpress, 2006. Disponível em: <<http://www.igeo.pt/gdr/publicacoes/s4.html>>. Acesso em: 07 out. 2008.

CAETANO, M.; SANTOS, T.; GONÇALVES, L. Cartografia de ocupação do solo com imagens de satélite: estado da arte. In: ENCONTRO NACIONAL DE UTILIZADORES DE INFORMAÇÃO GEOGRÁFICA, 7, 2002, Oreias. **Anais...** Lisboa: ESIG, 2002.

CAETANO, M.; NAVARRO, A.; SANTOS, J. P. Improving urban areas mapping with satellite imagery by contextual analysis and integration of a road network map. In: ANNUAL CONFERENCE AND EXHIBITION OF THE REMOTE SENSING SOCIETY UNIVERSITY OF READING, 23, 1997, United Kingdom. **Proceedings...** United Kingdom: Remote Sensing Society, 1997.

CANTERS, F. Evaluating the uncertainty of area estimates derived from fuzzy land-cover classification. **Photogrammetric Engineering and Remote Sensing**, v. 63, n. 4, p. 403-414, 1997.

CAO, C.; LAM, N. S. Understanding the scale and resolution effects in remote sensing and GIS. In: QUATTROCHI, D. A.; GOODCHILD, M. F. **Scale in remote sensing and GIS**. New York: Lewis, 1997.

CARTER, D. B. **Analysis of multiresolution data fusion techniques**. 1998. 54 p. Thesis (Master of Science of Geography) – Faculty of the Virginia Polytechnic Institute and State University, Virginia.



CONAMA – CONSELHO NACIONAL DO MEIO AMBIENTE. Resolução nº 303, de março de 2002. **Diário Oficial da União**, Brasília, DF, mai. 2002.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1999.

CPTI – COOPERATIVA DE SERVIÇOS, PESQUISAS TECNOLÓGICAS E INDUSTRIAIS. **Diagnóstico da situação dos recursos hídricos da UGRHI – 22 Pontal do Paranapanema**: relatório zero. São Paulo: CPTI, 1999. CD-ROM.

CROITORU, A. et al. The rational function model: a unified 2D and 3D spatial data generation scheme. In: ASPRS ANNUAL CONFERENCE, 70, 2004, Denver, Colorado. **Proceedings...** Denver: ASPRS, 2004.

DEKKER, R. J. Texture analysis of urban areas in ERS SAR imagery for map updating. In: IEEE/ISPRS JOINT WORKSHOP ON REMOTE SENSING AND DATA FUSION OVER URBAN AREAS, 2001, Rome, Italy. **Proceedings...** Rome: IEEE/ISPRS, 2001. p. 226-230.

DIGITALGLOBE. **QuickBird imagery products: products guide**. 2006. Disponível em: <<http://www.digitalglobe.com>>. Acesso em: 19 jan. 2008.

DI GREGORIO, A. **Land cover classification system (LCCS), version 2**: classification concepts and user manual. Rome: FAO, 2004.

DNR – DEPARTMENT OF NATURAL RESOURCES OF OHIO. **Ohio land-use/land cover information**. Ohio: DNR, 1990. Disponível em: <<http://myapa.planning.org/lbcs/OtherStandards/>>. Acesso em: 15 nov. 2008.

DRECKI, I. Visualization of uncertainty in geographical data. In: GOODCHILD, M. F.; SHI, W.; FISHER, P. F. **Spatial data quality**. London: Taylor & Francis, 2002.

EASTMAN, J R. **IDRISI Andes**: guide to GIS and image processing. Manual version 15. Worcester: Clark University, 2006.

EASTMAN, J. R.; LANEY, R. M. Bayesian soft classification for sub-*pixel* analysis: a critical evaluation. **Photogrammetric Engineering and Remote Sensing**, v. 68, n. 11, p. 1149-1154, 2002.



EC – EUROPEAN COMMISSION. **LUCAS 2006 (Land use / cover area frame survey) – Technical reference document C-3: nomenclature.** 2006. Disponível em: <[http://circa.europa.eu/irc/dsis/landstat/info/data/survey\\_documentation.htm](http://circa.europa.eu/irc/dsis/landstat/info/data/survey_documentation.htm)>. Acesso em: 06 fev. 2008.

EEA – EUROPEAN ENVIRONMENTAL AGENCY. **CORINE land cover – part 1: methodology.** Bruxelas: EEA, 1995. Disponível em: <<http://reports.eea.eu.int>>. Acesso em: 13 jan. 2008.

EHLERS, M. Sensoriamento remoto para usuários de SIG – sistemas sensores e métodos: entre as exigências do usuário e a realidade. In: BLASCHKE, T; KUX, H. **Sensoriamento remoto e SIG avançados.** 2. ed. São Paulo: Oficina de Textos, 2007.

ESTEVAM, E. A. **Classificação de áreas de favelas a partir de imagens IKONOS: viabilidade de uso de uma abordagem orientada a objetos.** 2006. 127 f. Dissertação (Mestrado em Ciências Cartográficas) – Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente.

FELGUEIRAS, C. A. **Modelagem ambiental com tratamento de incertezas em SIG: o paradigma geoestatístico por indicação.** 1999. 212 f. Tese (Doutorado em Computação Aplicada) – Instituto de Pesquisas Espaciais, São José dos Campos.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais.** São Paulo: Oficina de Textos, 2002.

FONSECA, L. M. G. **Processamento digital de imagens.** São José dos Campos: INPE, 2000.

FOODY, G. M. A fuzzy sets approach to the representation of vegetation continua from remotely sensed data: an example from lowland heath. **Photogrammetric Engineering and Remote Sensing**, v. 58, n. 2, p. 221-225, 1992.

FOODY, G. M. et al. Non-linear mixture modelling without end-members using an artificial neural network. **International Journal of Remote Sensing**, v. 18, n. 4, p. 937-953, 1997.

FRANKLIN, S. E.; MAUDIE, A. J.; LAVIGNE, M. B. Using spatial co-occurrence texture to increase forest structure and species composition classification accuracy, **Photogrammetric Engineering and Remote Sensing**, v. 67, n. 7, p. 849-855, 2001.

GALO, M. L. B. T. **Aplicação de redes neurais artificiais e sensoriamento remoto na caracterização ambiental do Parque Estadual Morro do Diabo.** 2000. 205 f. Tese



(Doutorado em Ciências da Engenharia Ambiental) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

GALO, M. L. B. T.; IMAI, N. N.; ENNES, R. Uma avaliação de imagens multiespectrais de alta resolução espacial obtidas por sistema de sensoriamento remoto aerotransportado na discriminação de alvos urbanos. In: CONGRESSO DE PLANEAMENTO URBANO, REGIONAL, INTEGRADO E SUSTENTÁVEL, 2, 2006, Braga, Portugal. **Anais...** Braga: Universidade do Minho, 2006. p. 1-6.

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de imagens**. 2. ed. São Paulo: Edgard Blücher, 2000.

GOODCHILD, M. F.; SHI, W.; FISHER, P. F. **Spatial data quality**. London: Taylor & Francis, 2002.

GOPAL, S.; WOODCOCK, C. Theory and methods for accuracy assessment of thematic maps using fuzzy sets. **Photogrammetric Engineering and Remote Sensing**, v. 60, n. 2, p. 181-188, 1994.

GORHAM, B. **Final report: the 1999 Arkansas land-use / land-cover project**. 1999. Disponível em: <[http://www.cast.uark.edu/local/arlulc99/final\\_report.htm](http://www.cast.uark.edu/local/arlulc99/final_report.htm)>. Acesso em: 07 fev. 2008.

GUERRA, A. T. **Dicionário geológico-geomorfológico**. 8. ed. Rio de Janeiro: IBGE, 1993.

HARALICK, R.; SHANMUGAM, K.; DINSTEN, I. Texture features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. SMC-3, n. 6, p. 610-621, 1973.

HAYKIN, S. **Neural networks: a comprehensive foundation**. 2. ed. New Jersey: Prentice-Hall, 1999.

HEROLD, M. et al. The spectral dimension in urban land cover mapping from high resolution optical remote sensing. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF URBAN AREAS, 3, 2002, Istanbul, Turkey. **Proceedings...** Istanbul: Istanbul Technical University, 2002. p. 77-84.

HEROLD, M.; LIU, X.; CLARKE, K. C. Spatial metrics and image texture for mapping urban land use. **Photogrammetric Engineering and Remote Sensing**, v. 69, n. 9, 2003. p. 991-1001.



HÖFLING, J. C. **Introdução à biologia marinha e oceanografia**. Campinas: Edição do Autor, 2000.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Classificação fisionômico-ecológica das formações neotropicais**. Rio de Janeiro: IBGE, 1991.

\_\_\_\_\_. **Classificação da vegetação brasileira, adaptada a um sistema universal**. Rio de Janeiro: IBGE, 1992a. Disponível em: <<http://biblioteca.ibge.gov.br/visualizacao/monografias/GEBIS%20-%20RJ/classificacaovegetal.pdf>>. Acesso em: 10 fev. 2008.

\_\_\_\_\_. **Manual técnico da vegetação brasileira**. Manuais Técnicos em Geociências, n. 1. Rio de Janeiro: IBGE, 1992b. Disponível em: <<http://biblioteca.ibge.gov.br/visualizacao/monografias/GEBIS%20-%20RJ/ManuaisdeGeociencias/Manual%20Tecnico%20da%20Vegetacao%20Brasileira%20n.1.pdf>>. Acesso em: 10 nov. 2007.

\_\_\_\_\_. **Manual técnico de uso da terra**. Manuais Técnicos em Geociências, n. 7. Rio de Janeiro: IBGE, 1999a. Disponível em: <<ftp://geoftp.ibge.gov.br/documentos/recursosnaturais/usodaterra/manualusodaterra.pdf>>. Acesso em: 01 out. 2007.

\_\_\_\_\_. **Noções básicas de cartografia**. Manuais Técnicos em Geociências, n. 7. Rio de Janeiro: IBGE, 1999b.

\_\_\_\_\_. **Uso da terra no Estado do Amapá**. Projeto Levantamento e Classificação do Uso da Terra: Relatório Técnico. Rio de Janeiro: IBGE, 2004a. Disponível em: <[ftp://geoftp.ibge.gov.br/documentos/recursosnaturais/usodaterra/usoterra\\_AP.pdf](ftp://geoftp.ibge.gov.br/documentos/recursosnaturais/usodaterra/usoterra_AP.pdf)>. Acesso em: 01 abr. 2008.

\_\_\_\_\_. **Vocabulário básico de recursos naturais e meio ambiente**. 2 ed. Rio de Janeiro: IBGE, 2004b.

\_\_\_\_\_. **Uso da terra no Estado do Roraima**. Projeto Levantamento e Classificação do Uso da Terra: Relatório Técnico. Rio de Janeiro: IBGE, 2005. Disponível em: <[ftp://geoftp.ibge.gov.br/documentos/recursosnaturais/usodaterra/usoterra\\_RR.pdf](ftp://geoftp.ibge.gov.br/documentos/recursosnaturais/usodaterra/usoterra_RR.pdf)>. Acesso em: 01 abr. 2008.

\_\_\_\_\_. **Manual técnico de uso da terra**. Manuais Técnicos em Geociências, n. 7. 2. ed. Rio de Janeiro: IBGE, 2006a.



IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Uso da terra no Estado do Acre**. Projeto Levantamento e Classificação do Uso da Terra: Relatório Técnico. Rio de Janeiro: IBGE, 2006b. Disponível em: <[ftp://geofpt.ibge.gov.br/documentos/recursosnaturais/usodaterra/usoterra\\_AC.pdf](ftp://geofpt.ibge.gov.br/documentos/recursosnaturais/usodaterra/usoterra_AC.pdf)>. Acesso em: 01 abr. 2008.

\_\_\_\_\_. **Censo 2007**. 2007a. Disponível em: <<http://www.ibge.gov.br/cidadesat/default.php>>. Acesso em: 15 out. 2008.

\_\_\_\_\_. **Produção da pecuária municipal**. 2007b. Disponível em: <<http://www.ibge.gov.br/cidadesat/default.php>>. Acesso em: 15 out. 2008.

INPE – INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **CANASAT**. 2007a. Disponível em: <[www.dsr.inpe.br/mapdsr/](http://www.dsr.inpe.br/mapdsr/)>. Acesso em: 22 jul. 2008.

\_\_\_\_\_. **Spring**. 2007b. Disponível em: <<http://www.dpi.inpe.br/spring/portugues/index.html>>. Acesso em: 30 ago. 2008.

\_\_\_\_\_. **Catálogo de imagens**. 2008. Disponível em: <<http://www.dgi.inpe.br/CDSR/>>. Acesso em: 16 fev. 2008.

ISLAM, Z. **Fractals and fuzzy sets for modeling the heterogeneity and spatial complexity of urban landscapes using multiscale remote sensing data**. 2004. 310 p. Thesis (Doctor of Philosophy) – Department of Spatial Sciences, Curtin University of Technology, Perth.

JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. 2. ed. New Jersey: Prentice Hall, 1996.

\_\_\_\_\_. **Remote sensing of the environment: an earth resource perspective**. New Jersey: Prentice Hall, 2000.

KIM; M.; XU, B.; MADDEN, M. Object-based vegetation type mapping from on orthorectified multispectral IKONOS image using ancillary information. In: INTERNATIONAL CONFERENCE ON OBJECT-BASED IMAGE ANALYSIS, 2, 2008, Calgary Alberta, Canada. **Proceedings...** Calgary Alberta: ISPRS, 2008. p. 1-5.

KUX, H. J. H; PINHEIRO, E. S. Dados do satélite QUICKBIRD para o mapeamento do uso e cobertura da terra numa seção da Mata Atlântica no Estado do Rio Grande do Sul. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12, 2005, Goiânia, Brasil. **Anais...** Goiânia: INPE, 2005. p. 4509-4516.





LABEN, C. A.; BROWER, V. B.. Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening. **United States Patent 6011875**. 2000. Disponível em: <<http://www.freepatentsonline.com/6011875.html>>. Acesso em: 15 nov. 2008.

LEE, J. et al. A neural network approach to cloud classification. **IEEE Transactions on Geoscience and Remote Sensing**, v.28, n.5, p.846-55, 1990.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote sensing and image interpretation**. 5 ed. New York: John Wiley & Sons, 2004.

LIMA JR., O. S. **Análise de pontos por função fuzzy**. 2002. 166 f. Dissertação (Mestrado em Informática Aplicada) – Fundação Educacional Edson Queiroz, Universidade de Fortaleza, Fortaleza.

LIPPMANN, R. P. An introduction to computing with neural nets. **IEEE ASSP Magazine**, v. 4, p. 4-22, 1987.

LIZARAZO, I. Urban land cover and land use classification using high spatial resolution images and spatial metrics. In: WORKSHOP OF THE EARSEL SIG ON LAND USE AND LAND COVER, 2, 2006, Bonn, Germany. **Proceedings...** Bonn: ERASel, 2006. p. 292-298.

MA, Z.; REDMOND, R. L. Tau coefficient for accuracy assessment of classification of remote sensing data. **Photogrametric Engineering and Remote Sensing**, v. 61, n. 4, p. 435-439, 1995.

MACEACHREN, A. M. **Some truth with maps: a primer on symbolization and design**. Washington: Association of American Geographers, 1994.

MASELLI, F.; RODOLFI, A.; CONESE, C. Fuzzy classification of spatially degraded Thematic Mapper data for the estimation of sub-*pixel* components. **International Journal of Remote Sensing**, v. 17, n. 3, p. 537-551, 1996.

MDNR – MICHIGAN DEPARTMENT OF NATURAL RESOURCES. **Michigan land cover/use classification system – 2000**. 2001. Disponível em: <[http://www.rsgis.msu.edu/pdf/lclu/Michigan\\_LC\\_LU\\_Classification\\_System\\_2000.pdf](http://www.rsgis.msu.edu/pdf/lclu/Michigan_LC_LU_Classification_System_2000.pdf)>. Acesso em: 11 mar. 2008.

MEOEA – MASSACHUSETTS EXECUTIVE OFFICE OF ENVIRONMENTAL AFFAIRS. **MassGIS datalayer descriptions and a guide to user services**. Massachusetts:



Massachusetts Executive Office of Environmental Affairs, 1992. Disponível em: <<http://myapa.planning.org/lbcs/OtherStandards/>>. Acesso em: 15 nov. 2008.

MICHEL, L.; HEYMAN, Y. **Nancy urban ecosystems classification categories**. Graz: French Ministry of Environment, 1993. Disponível em: <<http://myapa.planning.org/lbcs/OtherStandards/>>. Acesso em: 15 nov. 2008.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. São José dos Campos: INPE, 2001.

MOURA, E. V. L.; SOUZA, E. A.; ANDRÉA, M. V. **Pastagens degradadas: em busca da solução**. 2007. Disponível em: <[www.artigocientifico.com.br](http://www.artigocientifico.com.br)>. Acesso em: 10 abr. 2008.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 2. ed. São Paulo: Edgard Blucher, 1992.

OLIVEIRA, C. **Curso de cartografia moderna**. 2 ed. Rio de Janeiro: IBGE, 1993.

OMNR – ONTARIO MINISTRY OF NATURAL RESOURCES. **Ontario land cover data base: user's manual**. Canada: OMNR, 1999.

PAES, F. C.; PINTO, S. A. F.; DUTRA, L. V. Um estudo exploratório para obtenção de índices de qualidade de vida urbana (IQV) utilizando imagens de alta resolução do satélite IKONOS II. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11, 2003, Belo Horizonte, Brasil. **Anais...** Belo Horizonte: INPE, 2003. p. 1907-1914.

PERUSI, M. C. **Alterações antrópicas de argissolos decorrentes do uso e manejo e reflexo na densidade demográfica no município de Anhumas-SP**. 2001. 104 f. Dissertação (Mestrado em Energia na Agricultura) – Faculdade de Ciências Agronômicas, Universidade Estadual Paulista, Botucatu.

PESARESI, M. Textural classification of very high-resolution satellite imagery: empirical estimation of the interaction between window size and detection accuracy in urban environment. In: INTERNATIONAL CONFERENCE ON IMAGE PROCESSING, 1999, Kobe, Japan. **Proceedings...** Kobe: IEEE, 1999. p. 114-118.

PINHO, C. M. D.; FEITOSA, F. F.; KUX, H. J. H. Classificação automática de cobertura do solo urbano em imagens IKONOS: comparação entre a abordagem *pixel-a-pixel* e orientada a objetos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12, 2005, Goiânia, Brasil. **Anais...** Goiânia: INPE, 2005. p. 4217-4224.



PINHO, C. M. D.; KUX, H. J. H. Dados do Quickbird para subsidiar o planejamento urbano: uma proposta metodológica, município de São José dos Campos, SP, Brasil. In: SIMPOSIO LATINOAMERICANO SOBRE PERCEPCIÓN REMOTA Y SISTEMAS DE INFORMACIÓN ESPACIAL, 11, 2004, Santiago, Chile. **Anais...** Santiago: SELPER, 2004. p. 1-10.

PINHO, C. M. D.; KUX, H. J. H.; ALMEIDA, C. M. Influência de diferentes padrões de ocupação do solo urbano na qualidade de mapeamentos de cobertura do solo em imagens de alta resolução espacial: estudo de caso São José dos Campos (SP). In: BLASCHKE, T; KUX, H. **Sensoriamento remoto e SIG avançados**. 2. ed. São Paulo: Oficina de Textos, 2007.

PINHO, C. M. D.; RENNÓ, C. D.; KUX, H. J. H. Avaliação de técnicas de fusão aplicadas à imagem QuickBird. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12, 2005, Goiânia, Brasil. **Anais...** Goiânia: INPE, 2005. p. 4225-4232.

RAIA JR., A. A. **Acessibilidade e mobilidade na estimativa de um índice de potencial de viagens utilizando redes neurais artificiais e sistemas de informações geográficas**. 2000. 217 f. Tese (Doutorado em Engenharia Civil) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

RICHARDS, J. A.; JIA, X. **Remote sensing digital image analysis: an introduction**. 3. ed. New York: Springer-Verlag, 1999.

ROBINOVE, C. J. The logic of multispectral classification and mapping of land. **Remote sensing of environment**, v. 11, p. 231-244, 1981.

ROSENFELD, G. H.; FITZPATRICK-LINS, K. A coefficient of agreement as a measure of thematic classification accuracy. **Photogrammetric Engineering and Remote Sensing**, v. 52, n. 2, p. 223-227, 1986.

ROSS, J. L. S.; MOROZ, I. C. Mapa geomorfológico do Estado de São Paulo. **Revista do Departamento de Geografia**, v. 10, p. 41-56, 1996.

RSI – RESEARCH SYSTEMS INC. **ENVI user's guide**. RSI, 2007.

SABO, L. A. **Análise da incerteza na representação de classes temáticas resultantes da aplicação de uma rede neural artificial**. 2006. 122 f. Dissertação (Mestrado em Ciências Cartográficas) – Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente.



SANTOS, R. L. et al. A teoria da incerteza aplicada à classificação de imagens. In: CONGRESSO BRASILEIRO DE CARTOGRAFIA, 21, Belo Horizonte, Brasil. **Anais...** Belo Horizonte: Sociedade Brasileira de Cartografia, 2003.

SANTOS, V. T. M. **Aplicação de classificação digital de imagens orbitais no mapeamento de uso da terra**. 2006. 122 f. Dissertação (Mestrado em Geologia) – Instituto de Geociências, Universidade de Brasília, Brasília.

SCARPINELLA, G. D'A. **Reflorestamento no Brasil e o protocolo de Quioto**. 2002. 182 f. Dissertação (Mestrado em Energia) – Instituto de Eletrotécnica e Energia, Universidade de São Paulo, São Paulo.

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. 3. ed. San Diego: Elsevier, 2007.

SHACKELFORD, A. K.; DAVIS, C. H. A hierarchical fuzzy classification approach for high-resolution multispectral data over urban areas. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 9, p. 1920-1931, 2003.

SILVA, E. G.; PERUSI, M. C.; NUNES, J. O. R. Aplicação dos conhecimentos geográficos para a compreensão dos processos de formação, degradação/conservação dos solos da região de Presidente Prudente-SP. In: SEMANA DA GEOGRAFIA, 6, 2005, Presidente Prudente, Brasil. **Anais...** Presidente Prudente: UNESP, 2005. p. 1-6.

SILVA FILHO, D. F. et al. Indicadores de floresta urbana a partir de imagens aéreas multiespectrais de alta resolução. **Scientia Forestalis**, v. 67, n. 67, p. 88-100, 2005.

SOUZA, I. M. et al. Mapeamento do uso do solo urbano através da classificação por regiões baseada em medidas texturais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11, 2003, Belo Horizonte, Brasil. **Anais...** Belo Horizonte: INPE, 2003. p. 1967-1968.

STEIN, A. et al. **Spatial statistics for remote sensing**. Boston: Kluwer Academic Publishers, 1999.

TATIBANA, C. Y.; KAETSU, D. Y. **Uma introdução às redes neurais**. 2008. Disponível em: <[www.din.uem.br/ia/neurais](http://www.din.uem.br/ia/neurais)>. Acesso em: 16 set. 2008.

TEEFFELEN, P. V.; JONG, S.; VAN DER BERG, L. Urban monitoring: new possibilities of combining high spatial resolution IKONOS images with contextual image analysis



techniques. In: IEEE/ISPRS JOINT WORKSHOP ON REMOTE SENSING AND DATA FUSION OVER URBAN AREAS, 2001, Rome, Italy. **Proceedings...** Rome: IEEE/ISPRS, 2001. p. 265-269.

TUBB, N. R. A development path to success in neural computing. **Expert Systems Applications**, v. 9, n. 5, p. 5-9, 1993.

VAN DER WEL, F. J. M.; VAN DER GAAG, L. C.; GORTE, B. G. H. Visual exploration of uncertainty in remote sensing classification. **Computers and Geosciences**, v. 24, n. 4, p. 335-343, 1998.

VENTURIERI, A.; SANTOS, J. R. Técnicas de classificação de imagens para análise de cobertura vegetal. In: ASSAD, E. D.; SANO, E. E. **Sistema de informações geográficas: aplicações na agricultura**. 2. ed. Brasília: Embrapa, 1998.

VILELA, M. F. et al. Avaliação de técnicas de realce e classificação digital na elaboração de um mapa de uso da terra mediante uma imagem TM/LANDSAT-5. **Revista Árvore**, Viçosa, v. 24, n. 2, p. 161-173, 2000.

WANG, F. Fuzzy supervised classification of remote sensing images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 28, n. 2, p. 194-201, 1990.

WANG, F.; BRENT HALL, G.; SUBARYONO. Fuzzy information representation and processing in conventional GIS software: database design and application. **International Journal Geographical Information Systems**, v. 4, n. 3, p. 261-283, 1990.

WANG, Z. et al. A comparative analysis of image fusion methods. **IEEE Transactions on Geoscience and Remote Sensing**, v. 43, n. 6, p. 1391-1402, 2005.

WHITTIER COLLEGE. **Studio project**: categories for the environmental justice project. California: Whittier College, 1997. Disponível em: <<http://myapa.planning.org/lbcs/OtherStandards/>>. Acesso em: 15 nov. 2008.

YU, Q. et al. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. **Photogrammetric Engineering and Remote Sensing**, v. 72, n. 7, p. 799-811, 2006.

ZADEH, L. A. Fuzzy sets. **Information and Control**, v. 8, p. 339-353, 1965.



ZHANG, J; FOODY, G. M. Fully-fuzzy supervised classification of sub-urban land cover from remotely sensed imagery: statistical and artificial neural network approaches. **International Journal of Remote Sensing**, v. 22, n. 4, p. 615-628, 2001.

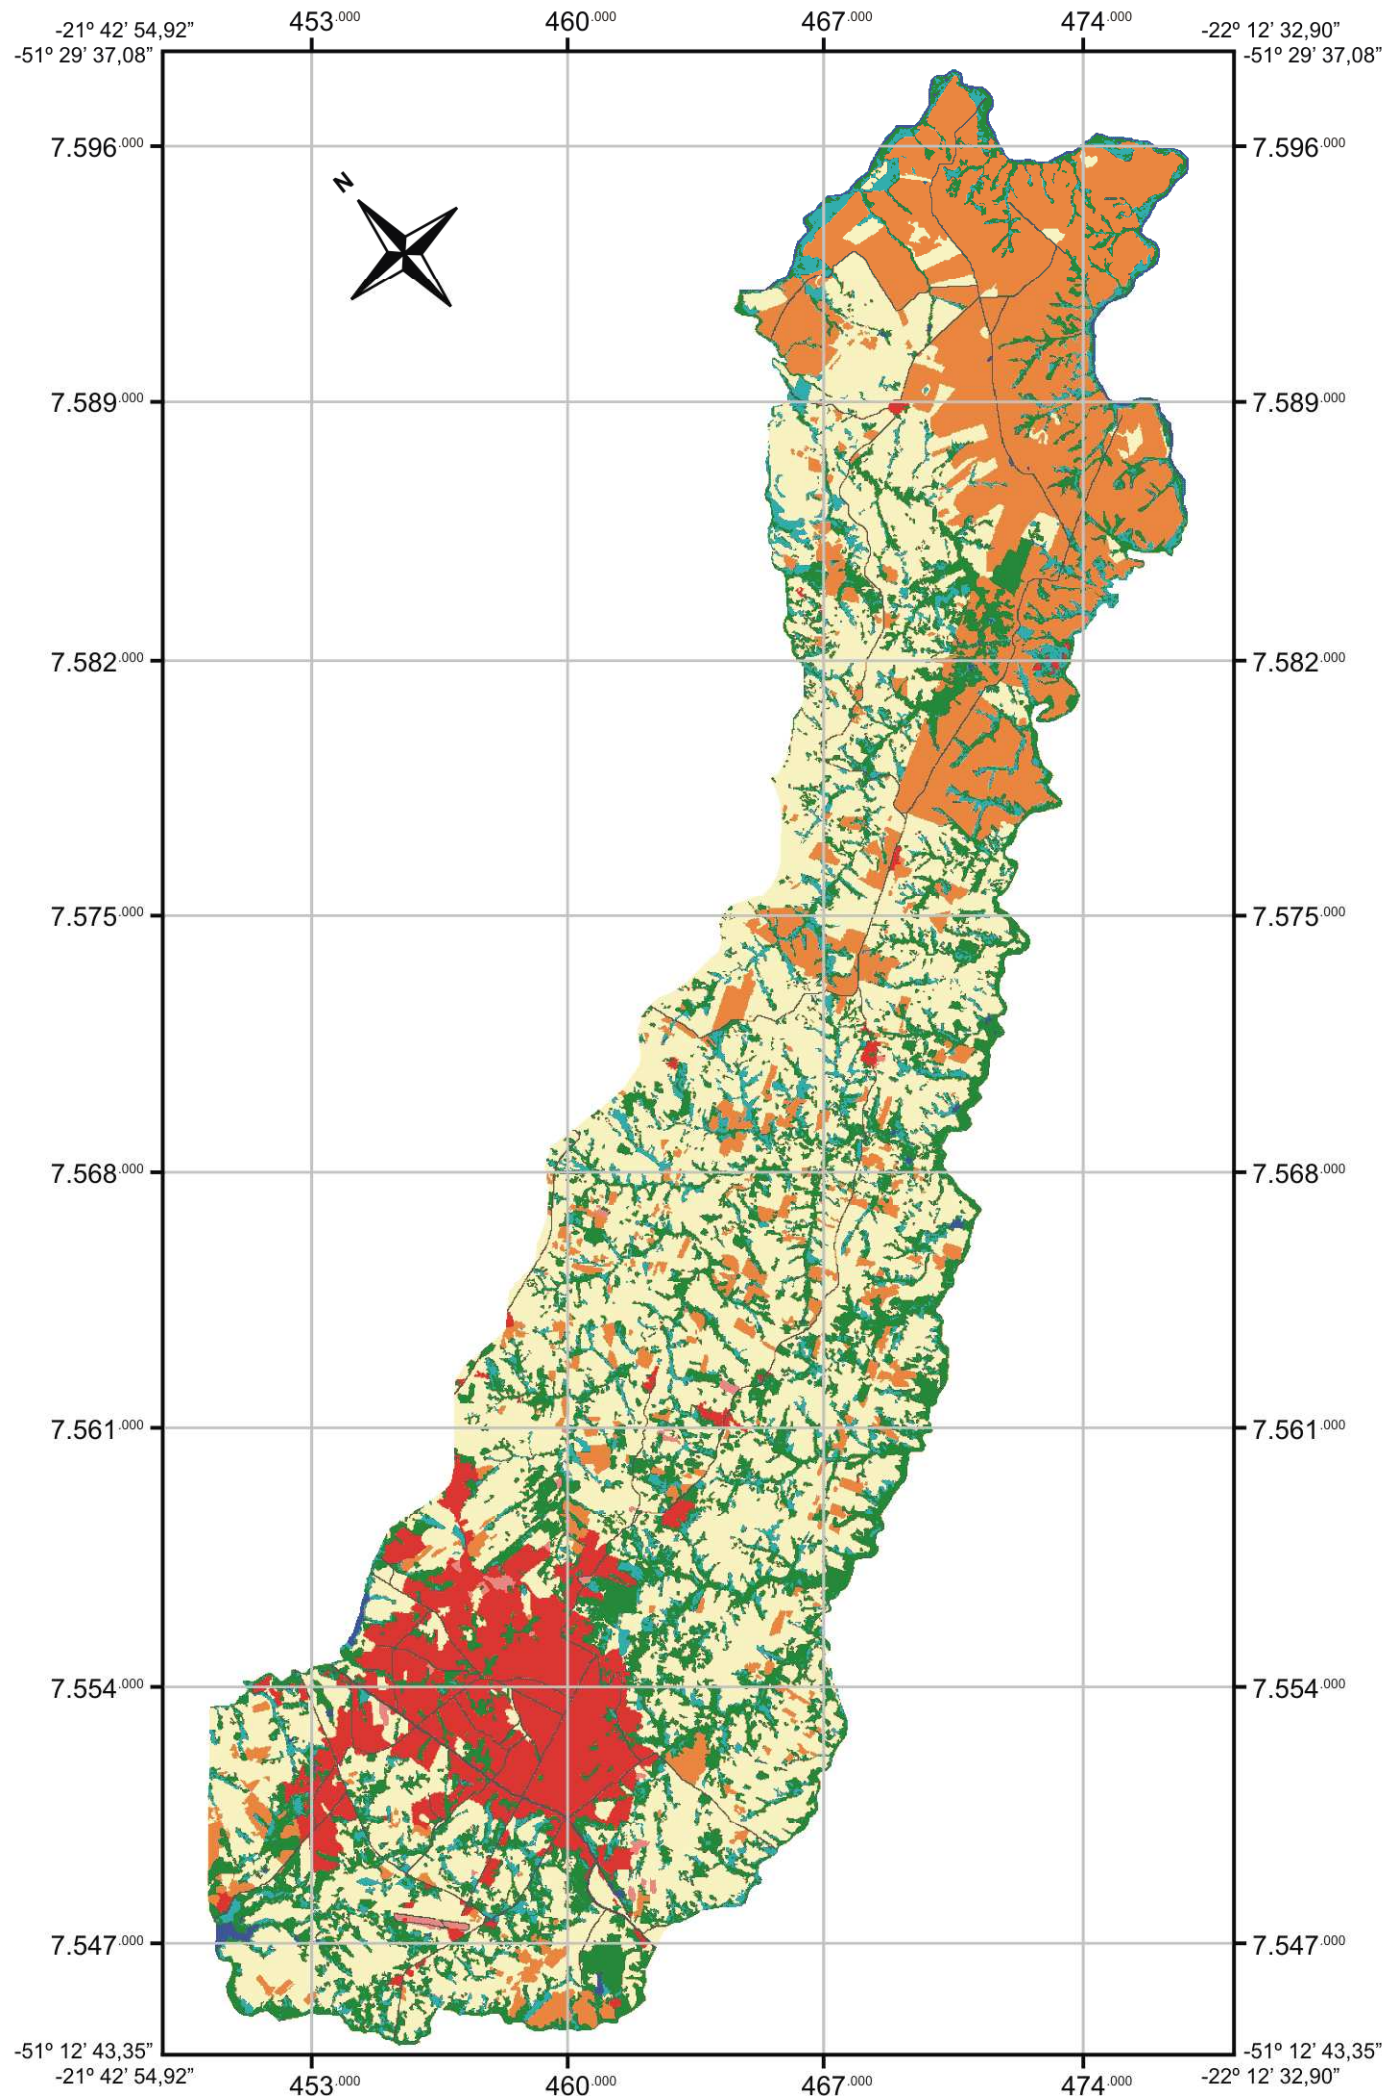
ZHANG, J; STUART, N. Fuzzy methods for categorical mapping with image-based land cover data. **International Journal Geographical Information Science**, v. 15, n. 2, p. 175-195, 2001.

ZHANG, Q. et al. Study of urban spatial patterns from SPOT panchromatic imagery using textural analysis. **International Journal of Remote Sensing**, v. 24, n. 21, p. 4137-4160, 2003.











## **APÊNDICE A**

**MAPA DA COBERTURA DA TERRA DO MUNICÍPIO DE PRESIDENTE  
PRUDENTE (SP) PARA O NÍVEL II DO SISTEMA HIERÁRQUICO DE  
CLASSIFICAÇÃO EM ESCALA REGIONAL  
(Formato de impressão A3)**

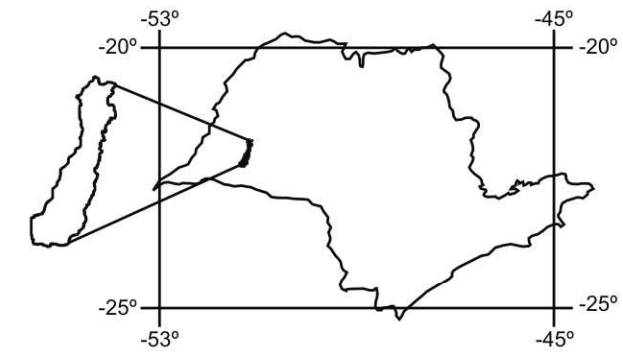


# MAPA DA COBERTURA DA TERRA DO MUNICÍPIO DE PRESIDENTE PRUDENTE SP

## LEGENDA:


- |   |  |
|---|--|
|  EDIFICAÇÃO URBANA / RURAL |  ÁREA ÚMIDA CONTINENTAL     |
|  MALHA VIÁRIA              |  ÁGUA CONTINENTAL           |
|  CULTURA AGRÍCOLA          |  FORMAÇÃO FLORESTAL         |
|  PASTAGEM                  |  ÁREA SEM COBERTURA VEGETAL |

### SITUAÇÃO DA ÁREA MAPEADA NO ESTADO DE SÃO PAULO



ESCALA 1 : 200.000

1 cm = 2 km



CONVERGÊNCIA MERIDIANA (c): 00° 07' 55,92"  
 DECLINAÇÃO MAGNÉTICA (d): -17° 48' 48,27"  
 VARIAÇÃO ANUAL DE "d": -00° 07' 56,33"

PROJEÇÃO: UTM (UNIVERSAL TRANSVERSA DE MERCATOR)  
 DATUM HORIZONTAL: SOUTH AMERICAN DATUM 1969  
 DATUM VERTICAL: MARÉGRAFO DE IMBITUBA (SC)  
 MERIDIANO CENTRAL: - 51°  
 FUSO: 22  
 QUADRÍCULA DE 7000 METROS

FONTE: IMAGEM DE SATÉLITE TM/LANDSAT-5  
 DATA DA IMAGEM: SETEMBRO DE 2007  
 DATA DO MAPEAMENTO: JUNHO DE 2008



FCT / UNESP - PRESIDENTE PRUDENTE SP

FACULDADE DE CIÊNCIAS E TECNOLOGIA / UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"  
 PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS CARTOGRÁFICAS - DEPARTAMENTO DE CARTOGRAFIA

APOIO: 

RESPONSÁVEL: FERNANDA DE ALMEIDA PRADO  
 ENGENHEIRA CARTÓGRAFA - CREA 5062499776 SP



## **APÊNDICE B**

**MAPA DA COBERTURA DA TERRA DA CIDADE DE PRESIDENTE  
PRUDENTE (SP) PARA O NÍVEL III DO SISTEMA HIERÁRQUICO DE  
CLASSIFICAÇÃO EM ESCALA URBANA  
(Formato de impressão A3)**





# MAPA DA COBERTURA DA TERRA DA CIDADE DE PRESIDENTE PRUDENTE SP

## LEGENDA:


- CERÂMICA
- COBERTURA DE FIBROCIMENTO
- CONCRETO
- COBERTURA METÁLICA
- ASFALTO
- OUTROS
- ÁRVORE / ARBUSTO
- GRAMADO
- SOLO
- SOMBRA
- CURSO D'ÁGUA
- LAGOA
- RESERVATÓRIO



FCT / UNESP - PRESIDENTE PRUDENTE SP  
 FACULDADE DE CIÊNCIAS E TECNOLOGIA  
 UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"  
 PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS CARTOGRÁFICAS  
 DEPARTAMENTO DE CARTOGRAFIA

APOIO: FAPESP

PROJEÇÃO: UTM (UNIVERSAL TRANSVERSA DE MERCATOR)  
 DATUM HORIZONTAL: SOUTH AMERICAN DATUM 1969  
 DATUM VERTICAL: MARÉGRAFO DE IMBITUBA (SC)  
 MERIDIANO CENTRAL: - 51° FUSO: 22  
 QUADRÍCULA DE 400 METROS  
 FONTE: IMAGENS MULTIESPECTRAL E PANCRÔMATICA QUICKBIRD II  
 DATA DAS IMAGENS: FEVEREIRO DE 2007  
 DATA DO MAPEAMENTO: OUTUBRO DE 2008



CONVERGÊNCIA MERIDIANA (c): 00° 09' 17,96"  
 DECLINAÇÃO MAGNÉTICA (d): -17° 47' 22,82"  
 VARIAÇÃO ANUAL DE "d": -00° 07' 59,48"

ESCALA 1 : 10.000

1 cm = 100 m



RESPONSÁVEL: FERNANDA DE ALMEIDA PRADO  
 ENGENHEIRA CARTÓGRAFA - CREA 5062499776 SP



# Livros Grátis

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

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

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

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

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