



UNIVERSIDADE TÉCNICA DE LISBOA
INSTITUTO SUPERIOR TÉCNICO

AVALIAÇÃO DAS IMAGENS MULTIESPECTRAIS
DO SATÉLITE IKONOS
PARA PRODUÇÃO DE CARTOGRAFIA DE OCUPAÇÃO DO SOLO

LUISA MARIA DA SILVA GONÇALVES
(Licenciada)

Dissertação para obtenção do Grau de Mestre em
Sistemas de Informação Geográfica

Orientador: Doutor Mário Sílvio Rochinha de Andrade Caetano

Co-Orientador: Doutor João Luís Gustavo Matos

Presidente: Doutor João Luís Gustavo Matos

Vogais: Doutor José António Pereira Tenedório

Doutor Mário Sílvio Rochinha de Andrade Caetano

Abril 2003

AGRADECIMENTOS

Desejo manifestar o meu sincero reconhecimento ao Doutor Mário Caetano, meu orientador científico, pelo esforço empreendido na minha orientação, pelo estímulo e sugestões, e pela disponibilidade que sempre demonstrou em apoiar esta dissertação.

Ao Doutor João Matos, meu co-orientador científico pelo apoio fornecido.

À Câmara Municipal da Marinha Grande pela disponibilização das imagens e informação necessárias para a realização do estudo e, em particular à Arq^a Isabel Roque, Eng^a Sandra Saraiva e Eng^a Patrícia que se mostraram sempre disponíveis em colaborar.

À Doutora Isabel Fonseca, Dr. Hugo Carrão e Eng^a Teresa Santos pelo apoio e amizade oferecido durante a realização desta dissertação.

Ao José Nogueira, pelo acompanhamento de todo o trabalho e estímulo para continuar.

Por fim, mas não com menos importância, aos meus pais e aos meus filhos, pela sua enorme compreensão.

RESUMO

Neste estudo são utilizados os novos dados imagem de grande resolução espacial do satélite IKONOS para produção de mapas de uso do solo, à escala 1:10 000, recorrendo a análise orientada por objectos, classificação *fuzzy* e análise de incerteza. Contrariamente aos métodos tradicionais, em que a extracção da informação é baseada no *pixel*, na análise orientada por objectos a classificação das imagens de satélite é efectuada a partir de objectos imagem. Com este método, o processamento de imagens aproxima-se mais dos processos cognitivos humanos do que as análises baseadas ao nível do *pixel*.

Inicialmente, foram obtidos os objectos imagem aplicando um algoritmo de segmentação multi-resolução. Em seguida, para proceder à sua classificação, foi construída uma base de conhecimento estruturada sob a forma de uma hierarquia de classes. A informação utilizada baseou-se em dados espectrais, forma, textura, relações de vizinhança, contexto e hierarquia dos objectos imagem. Foi aplicada uma classificação *fuzzy*, o que permitiu a integração das diferentes características dos objectos no processo de classificação e possibilitou a análise da incerteza temática.

A análise da incerteza revelou-se uma ferramenta de análise extremamente importante, no processo iterativo da classificação, para melhorar os resultados. Com base nos graus de pertença, relativamente à melhor e segunda melhor classificação, retidos no resultado da classificação de cada objecto, foi efectuada uma representação espacial da incerteza temática.

A área escolhida para testar a metodologia situa-se no Concelho da Marinha Grande, utilizaram-se imagens IKONOS de Setembro de 2000. A aplicação do método deu origem a um mapa de ocupação do solo com 16 classes, com grande detalhe temático nas áreas urbanas e uma precisão global superior a 80%. Avaliou-se ainda a dinâmica do uso do solo, por comparação do mapa produzido com uma cartografia obtida por análise visual de fotografia aérea, i.e. cartografia de ocupação do solo de 1990 (COS'90).

Palavras Chave: Detecção Remota, Imagens de Grande Resolução Espacial, IKONOS, Análise de Imagens Orientada por Objectos, Segmentação Multi-resolução, Classificação *Fuzzy*, Incerteza Temática, Sistemas de Informação Geográfica.

ABSTRACT

In this study, high spatial resolution images obtained by the new satellite IKONOS were used to produce a land cover map, on a scale of 1:10 000 using object oriented image analysis, fuzzy classification and uncertainty analysis. Image processing based on objects is much closer to the human cognitive processes than pixel-based systems. Image objects are obtained by applying multiresolution segmentation. For the classification of image objects, a knowledge base structured within a class hierarchy was developed. The attributes used were spectral data, shape, texture, neighbourhood relationships, context and image object hierarchy. The fuzzy classification used in this study allowed the use of thematic uncertainty analysis. The uncertainty analysis proved to be an extremely important analysis tool, in the iterative classification process. Based on the class membership, in relation to the first and second best classifications, the thematic uncertainty was spatially represented, giving the map user an indication of the error presented in each landscape unit.

The methodology was tested on an area in Marinha Grande council using IKONOS images taken in September 2000. The final land cover map has 16 classes, (with higher thematic detail in urban areas), and the global precision was higher than 80%. Land cover dynamics, were also assessed comparing the map obtained in 2000 with one produced by visual analysis of aerial photography, i.e. 1990's cartography of land cover (COS'90).

Key Words: Remote Sensing, IKONOS, Object Oriented Image Analysis, Multiresolution Segmentation, Fuzzy Classification, Thematic Uncertainty, Geographic Information Systems

ACRÓNIMOS

AMP	Área Metropolitana do Porto
B	<i>Blue</i> (banda espectral azul)
CASI	<i>Compact Airbone Spectrographic Imager</i>
CLUSTERS	<i>Classification for Land Use Statistics: Eurostats Remote Sensing</i>
CMMG	Câmara Municipal da Marinha Grande
CNIG	Centro Nacional de Informação Geográfica
COS'90	Carta de Ocupação do Solo de 1990
DRABL	Direcção Regional de Agricultura da Beira Litoral
EROS	<i>Earth Resource Observation Satellite</i> (satélite)
ESIG	Encontro dos Utilizadores de Sistemas de Informação Geográfica
G	<i>Green</i> (banda espectral verde)
HRV	<i>Haute Résolution dans le Visible</i>
IGeoE	Instituto Geográfico do Exército
IGP	Instituto Geográfico Português
INE	Instituto Nacional de Estatística
IKONOS	(satélite)
Landsat	<i>Land Satellite</i> (satélite)
LNEC	Laboratório Nacional de Engenharia Civil
LMM	<i>Local Mean Matching</i>
MSS	<i>Multispectral Scanner</i> (sensor)
MSAVI	<i>Modified Soil Adjusted Vegetation Index</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NLUSS	<i>National Land Use Stock System</i>
NR	Nível Radiométrico
OA	<i>Overall Accuracy</i>
OrbView	(satélite)
PAN	<i>Panchromatic</i> (sensor)
QuickBird	(satélite)
R	<i>Red</i> (banda espectral vermelha)
Radar	<i>Radio Detection and Ranging</i>
RGB	<i>Red-Green-Blue</i>
RMSE	<i>Root Mean Square Error</i>
RSAC	<i>Regional Earth Science Application</i>
RVI	<i>Ratio Vegetation Index</i>

SIG	Sistema de Informação Geográfica
SPIN	(satélite)
SPOT	<i>Système Probatoire pour l' Observation de la Terre</i> (satélite)
TM	<i>Thematic Mapper</i> (sensor)
VHR	<i>Very High Resolution</i> (sensor)
XS	Modo de Funcionamento Multiespectral do Sensor HRV

INDICE

CAPÍTULO 1 - INTRODUÇÃO	1
1.1 DETECÇÃO REMOTA: UM INSTRUMENTO ADEQUADO PARA A CARTOGRAFIA DE OCUPAÇÃO DO SOLO DE ÁREAS URBANAS	1
1.2 METODOLOGIAS RECENTES PARA EXPLORAÇÃO DE IMAGENS DE SATÉLITE DE GRANDE RESOLUÇÃO ESPACIAL	8
1.3 CARTOGRAFIA TEMÁTICA COM IMAGENS DE GRANDE RESOLUÇÃO ESPACIAL: ESTADO DA ARTE.....	10
1.4 OBJECTIVOS DO ESTUDO.....	18
1.5 ORGANIZAÇÃO DO ESTUDO.....	19
CAPÍTULO 2 – PRODUÇÃO DE CARTOGRAFIA DE OCUPAÇÃO DO SOLO COM IMAGENS SATÉLITE: DAS METODOLOGIAS TRADICIONAIS ÀS MAIS RECENTES....	20
2.1 ETAPAS COMUNS AO PROCESSO PRODUTIVO DE CARTOGRAFIA DE OCUPAÇÃO DO SOLO	20
2.2 VISUALIZAÇÃO GRÁFICA DA INCERTEZA	35
CAPÍTULO 3 - METODOLOGIA PROPOSTA PARA PRODUÇÃO DE CARTOGRAFIA TEMÁTICA DE OCUPAÇÃO DO SOLO	39
3.1 DEFINIÇÃO DA NOMENCLATURA	40
3.2 PRÉ - PROCESSAMENTO DA IMAGEM.....	41
3.3 EXTRACÇÃO DA INFORMAÇÃO TEMÁTICA COM BASE NA ANÁLISE DE IMAGEM ORIENTADA POR OBJECTOS	41
3.3.1 Segmentação da imagem	43
3.3.2 Características dos objectos imagem	47
3.3.3 Desenvolvimento de bases de conhecimento	49
3.4 AVALIAÇÃO DA QUALIDADE DOS RESULTADOS OBTIDOS.....	56
3.5 ANÁLISE E VISUALIZAÇÃO GRÁFICA DA INCERTEZA TEMÁTICA	57
3.6 INTEGRAÇÃO DE DADOS SIG	59
CAPÍTULO 4 – IMPLEMENTAÇÃO DA METODOLOGIA DESENVOLVIDA NO CONCELHO DA MARINHA GRANDE	60
4.1 ÁREA DE ESTUDO	60
4.2 BASE DE DADOS	62
4.2.1 Imagens de satélite	62
4.2.2 Dados auxiliares.....	63
4.3 ESTRUTURAÇÃO E INTRODUÇÃO DOS DADOS RECOLHIDOS NO MUNICÍPIO NUM SISTEMA DE INFORMAÇÃO GEOGRÁFICA	65
4.4 SOFTWARE.....	66
4.5. PRÉ - PROCESSAMENTO DOS DADOS.....	66

4.5.1. Correção geométrica.....	66
4.5.2 Correção atmosférica	68
4.6 ANÁLISE EXPLORATÓRIA DOS DADOS	69
4.7 EXTRACÇÃO DA INFORMAÇÃO TEMÁTICA A PARTIR DOS DADOS IMAGEM	70
4.7.1 Esquema de classificação.....	70
4.7.2. Segmentação da imagem	71
4.7.3. Desenvolvimento de bases de conhecimento	78
4.7.4 Classificação	86
4.8 AVALIAÇÃO DA QUALIDADE DO MAPA DE OCUPAÇÃO DO SOLO PRODUZIDO.....	91
4.9 ANÁLISE E REPRESENTAÇÃO GRÁFICA DA INCERTEZA TEMÁTICA	96
4.10 AVALIAÇÃO DA DINÂMICA DA OCUPAÇÃO DO SOLO.....	105
4.11 MAPA DO USO DO SOLO MELHORADO PELA INTEGRAÇÃO DE DADOS SIG	114
CAPÍTULO 5 – CONCLUSÕES	118
REFERÊNCIAS BIBLIOGRÁFICAS	122
ANEXO 1 – NOMENCLATURA DE REFERÊNCIA.....	131
ANEXO 2 – ATRIBUTOS UTILIZADOS NA CLASSIFICAÇÃO	133
ANEXO 3 – ESTRUTURA PADRÃO DE CONTEÚDOS DO MODELO GEOGRÁFICO DE ÂMBITO MUNICIPAL.....	142
ANEXO 4 – ESTRUTURAÇÃO DA INFORMAÇÃO AUXILIAR NUM SISTEMA DE INFORMAÇÃO GEOGRÁFICA.....	145
ANEXO 5 – MAPA DOS DADOS AUXILIARES.....	153
ANEXO 6 – MAPA DE OCUPAÇÃO DO SOLO DE 2000.....	156
ANEXO 7 – DISTRIBUIÇÃO DOS PONTOS UTILIZADOS NA VALIDAÇÃO DOS MAPAS DE OCUPAÇÃO DO SOLO	159
ANEXO 8 – REPRESENTAÇÃO ESPACIAL DA INCERTEZA	161
ANEXO 9 –MAPA DE OCUPAÇÃO DO SOLO DE 2000 COM INTEGRAÇÃO DE DADOS AUXILIARES.....	163

INDICE DE FIGURAS

Figura 1.1 - Imagem IKONOS e Landsat-5TM do Concelho da Marinha Grande à escala 1:50 000. Fig. 1.1 a) imagem Landsat (30m de resolução espacial), composição RGB 421. Fig. 1.1 b) imagem IKONOS (4m de resolução espacial), composição RGB 321.....	6
Figura 1.2 - Imagem Landsat-5TM e IKONOS do Concelho da Marinha Grande à escala 1:10 000. Fig.1.2 a) imagem Landsat (30m de resolução espacial), composição RGB 421. Fig.1.2 b) imagem IKONOS (1m de resolução espacial) composição RGB 321.....	7
Figura 2.1 - Método por crescimento de regiões utilizando <i>pixels</i> conhecidos à partida: (a) matriz da imagem original cujos valores correspondem aos níveis de intensidade. Os <i>pixels</i> conhecidos a partir dos quais se inicia o processo correspondem, na matriz (a), à posição (3,2) e (3,4); (b) segmentação resultante, usando como critério de agregação a diferença, em valor absoluto, dos níveis de intensidade dos <i>pixels</i> vizinhos inferior a 3 NR; (c) segmentação resultante usando uma diferença em valor absoluto inferior a 8 NR. Adaptado de Gonzalez e Woods (1992).....	31
Figura 2.2 - Segmentação por divisão e fusão. Adaptado de Gonzalez e Woods (1992).	32
Figura 2.3 - Modelação da incerteza posicional e temática dos objectos usando o <i>S-model</i> (adaptado de Ehlers e Wenzhong (1996)).	38
Figura 3.1 - Esquema da metodologia proposta.....	42
Figura 3.2 - Rede hierárquica de objectos imagem (adaptado de Baatz <i>et al.</i> (2000)).....	43
Figura 3.3 - A imagem a) ilustra a segmentação de uma imagem Landsat com optimização exclusiva da heterogeneidade espectral. A imagem b) ilustra a segmentação com optimização da heterogeneidade espectral e da forma. Adaptado de Baatz <i>et al.</i> (2000).	45
Figura 3.4 - Exemplo de atributos associados aos objectos obtidos com a segmentação multi-resolução. Fig.3.4 a) média dos valores espectrais dos <i>pixels</i> que constituem os objectos na banda do infravermelho próximo. Fig. 3.4 b) perímetro dos objectos; Fig. 3.4 c) textura obtida a partir do desvio padrão dos seus sub-objectos. Nas imagens inferiores seleccionou-se um objecto e apresenta-se o seu valor na característica em causa.	47
Figura 3.5 - Exemplo de uma função de pertença rectangular e trapezoidal relativa ao atributo x para definir um conjunto M rígido (crisp), representado a vermelho, e um conjunto A <i>fuzzy</i> representado a azul. Adaptado de Baatz <i>et al.</i> (2000).	50
Figura 3.6 - Exemplo de três conjuntos <i>fuzzy</i> : urbano, agricultura e floresta definidos no espaço característico C , cuja variação de valores é apresentada no eixo do x, e caracterizados pela sobreposição de funções de pertença triangular e trapezoidal. No eixo dos y são apresentados os valores resultantes da transformação efectuada pelas funções de pertença e que representam o grau de pertença às classes. Adaptado de Baatz <i>et al.</i> (2000).	51
Figura 3.7 - Os exemplos a) e b) ilustram como as funções de pertença podem ser combinadas, através de operadores lógicos, para constituir uma descrição da classe. No exemplo a) a expressão A e B ou a expressão A e C têm que ser cumpridas pelos atributos dos objectos imagem, para que estes sejam classificados. No exemplo b) a expressão A e a expressão B ou C têm que ser cumpridas pelos atributos dos objectos imagem, para que estes sejam classificados.....	51
Figura 3.8 - Método do vizinho mais próximo.....	52
Figura 3.9 - Exemplo da função de pertença do vizinho mais próximo. O cálculo da função de pertença depende do valor da função declive e inicia-se a partir do objecto amostra (ponto verde). Para um valor da distância, entre o objecto amostra e o objecto a classificar, de 0.5 resulta um valor de pertença 0.7 à classe à qual o objecto amostra pertence. Se a distância fosse 1, o valor da função z(d) seria igual à função declive resultando um valor de pertença de 0.2.	53

Figura 3.10 - Classificação do vizinho mais próximo. Para o mesmo valor da distância entre objecto amostra e o objecto a classificar obtêm-se diferentes valores de pertença para diferentes valores da função declive. Os valores da função declive são de 0.3 e 0.05 para o cálculo da função azul e lilás, respectivamente.	54
Figura 3.11 - Hierarquia de classes.	55
Figura 4.1 - Localização do limite administrativo do Concelho da Marinha Grande e área de estudo (rectângulo verde). As folhas apresentadas são as da Carta Militar produzidas pelo Instituto Geográfico do Exército (escala 1:25 000) do respectivo Concelho.....	61
Figura 4.2 - Localização do limite da Mata Nacional de Leiria e Mata do Casal da Lebre, sob a administração da DRABL, face ao limite administrativo do Concelho da Marinha Grande.	62
Figura 4.3 - Localização da área abrangida pela imagem de satélite relativamente ao limite administrativo do Concelho e à Mata Nacional de Leiria.....	63
Figura 4.4 - Sobreposição da imagem IKONOS pancromática geo-referenciada com a cartografia à escala 1:2000 da CMMG.	67
Figura 4.5 - Sobreposição da imagem IKONOS multiespectral geo-referenciada (RGB 321) com a cartografia à escala 1:2000 da CMMG.	68
Figura 4.6 - Esquema da segmentação multi-resolução.	72
Figura 4.7 - Extracto com o resultado das quatro segmentações efectuadas com a imagem IKONOS (RGB 421), apresentando estruturas que se mantêm inalteráveis com a variação de escala e que são representadas apenas por um único objecto imagem.....	74
Figura 4.8 - Extracto da imagem IKONOS (RGB 421) com a sobreposição dos contornos dos objectos (representados a vermelho) resultantes de três segmentações efectuadas: Fig. 4.8 a) Segmentação do nível 2; Fig. 4.8 b) Segmentação do nível 3; Fig. 4.8 c) Segmentação do nível 4.....	75
Figura 4.9 - Área da imagem IKONOS (RGB 321) com a sobreposição dos contornos dos objectos, obtidos com a segmentação realizada no nível 4, representados a amarelo.	76
Figura 4.10 - Área da imagem IKONOS (RGB 341) relativa à zona do aterro lixeira com a sobreposição dos contornos dos objectos, gerados na segmentação, apresentados a vermelho: Fig. 4.10 a) Segmentação do nível 4, em que o objecto imagem gerado se apresenta ajustado a toda a estrutura do aterro lixeira; Fig. 4.10 b) Segmentação do nível 2, em que os objectos formados já permitem individualizar as estruturas dos edifícios.....	76
Figura 4.11 - Área da imagem IKONOS (RGB 421) relativa a uma zona com áreas agrícolas e urbanas com a sobreposição dos contornos dos objectos, gerados na segmentação, apresentados a vermelho. Fig. 4.11 a) Segmentação do nível 3 que apresenta um objecto que contém Áreas de ocupação agrícola e Áreas artificiais; Fig. 4.11 b) Segmentação do nível 2 em que os objectos formados já permitem individualizar as Áreas de ocupação agrícola.	77
Figura 4.12 - Extracto da imagem IKONOS (RGB 321) com sobreposição de objectos imagem, gerados com a segmentação, apresentados a vermelho, mal ajustados aos objectos reais. .77	
Figura 4.13 - Classificação da imagem segmentada e registada no nível 4. Fig. 4.13 a) Extracto com classificação obtida com o desenvolvimento hierárquico 4 em que a classe <i>Rural(4)</i> está representada a verde e a classe <i>Urbano(4)</i> a rosa. A localização do extracto apresentado, relativamente à área total da imagem classificada, está assinalada no canto inferior esquerdo do mapa, por um quadrado preto. Fig. 4.13 b) Imagem IKONOS (RGB 421) relativa à mesma área com a sobreposição dos polígonos extraídos correspondentes à classificação efectuada.	79
Figura 4.14 - Regras <i>fuzzy</i> conjugadas através do operador lógico 'ou', que permitiram extrair os equipamentos desportivos no desenvolvimento hierárquico 4. Para que os objectos sejam classificados como equipamentos desportivos têm de ser cumpridas a expressão A (d direcção principal) ou B (diferença da média entre os objectos vizinhos na banda do vermelho) ou C (média dos valores espectrais de cada objecto na banda do vermelho).	80
Figura 4.15 - Desenvolvimento hierárquico 4.	80

Figura 4.16 - Melhoria da extracção da informação correspondente às classes Aterro lixeira e Saibreira obtida com o desenvolvimento hierárquico 3. Fig. 4.16 a) Imagem IKONOS (RGB 421) com a sobreposição dos contornos dos objectos classificados no desenvolvimento hierárquico 4, relativos às classes Saibreira e Aterro lixeira. Fig. 4.16 b) Classificação efectuada com desenvolvimento hierárquico 4, em que a classe Saibreira está representada com cor laranja e a classe Aterro lixeira com cor cinzenta. As Fig. 4.16 c) e Fig. 4.16 d) apresentam os contornos e a classificação obtidos para as referidas classes a partir do desenvolvimento hierárquico 3.	81
Figura 4.17 - Desenvolvimento hierárquico 3	82
Figura 4.18 - Extracto da Imagem IKONOS com a sobreposição de informação da classe Espaço verde urbano (RGB 421). Fig. 4.18 a) Objecto classificado como floresta ' <i>2Floresta(3)</i> ' (cor verde) com um grau de pertença de 100%, rodeado de objectos classificados como área artificial ' <i>5Urbano(3)</i> ' (cor rosa). Fig. 4.18 b) Apresenta o mesmo objecto que, após aplicação de relações de vizinhança, ficou classificado como Espaço verde urbano ' <i>Espaço_Verde_Urbano(3)</i> ' com um grau de pertença de 100%.	83
Figura 4.19 - Desenvolvimento hierárquico 2	84
Figura 4.20 - Desenvolvimento hierárquico 1	85
Figura 4.21 - Classificação de edifícios com cobertura de telha vermelha com e sem utilização de informação de contexto. As Fig. 4.21 a) e Fig. 4.21 b) apresentam a classificação de edifícios com cobertura de telha vermelha (cor vermelha) sem utilização de informação de contexto. As Fig. 4.21 c) e Fig.4.21 d) apresentam o resultado da classificação após utilização de informação de contexto (RGB 341).	86
Figura 4.22 - Procedimento utilizado na classificação da imagem de satélite.	87
Figura 4.23 - Grupos semânticos.....	88
Figura 4.24 – Identificação de áreas industriais. Fig. 4.24 a) extracto com a classificação da imagem IKONOS em que a cor azul representa uma Zona industrial. Fig. 4.24 b) ampliação correspondente ao quadrado preto indicado na Fig. 4.24.	94
Figura 4.25 - Avaliação dos valores de pertença da melhor classificação do mapa final	98
Figura 4.26 - Percentagem de área relativamente a cada classe atribuída com pouca incerteza.....	101
Figura 4.27 - Percentagem de área relativamente a cada classe atribuída com muita incerteza.....	101
Figura 4.28 - Classificação da imagem com sobreposição da informação relativa à incerteza da classificação. As classes de ocupação do solo estão identificadas por cor, enquanto que a trama identifica a incerteza.	105
Figura 4.29 – Exemplo de diferenças de classificação entre a COS'90 e a COS'00 devido a características técnicas diferentes. Fig. 4.29 a) uma área da imagem IKONOS (RGB 341) com a sobreposição da classe identificada na COS'90 como Zona residencial descontínua (trama vermelha). Fig. 4.29 b) representa a mesma área com a sobreposição da classe Área com ocupação da agrícola identificada no estudo (linha a preto).	106
Figura 4.30 - Comparação entre a ocupação do solo de 1990 e 2000 relativamente às Áreas artificiais, Agrícolas e Florestal e Meios semi- naturais.....	107
Figura 4.31 - Transferências de ocupação do solo de 1990 para 2000 relativamente à informação correspondente ao nível 1 da nomenclatura de referência Artificial, Ocupação agrícola, Floresta e Meios semi- naturais	108
Figura 4.32 – Transferência de ocupação do solo florestal em 1990 para ocupação do solo agrícola em 2000. Fig. 4.32 a) Áreas classificadas como Áreas com ocupação agrícola em 2000 representadas a cor laranja. Fig. 4.32 b) A mesma área com a sobreposição da classificação de 1990 que correspondia a Ocupação florestal representada com trama verde (imagem IKONOS RGB 321).	109
Figura 4.33 - Transferências para Zonas com dominância de habitação.	110
Figura 4.34 – Exemplo de uma transição impossível (imagem IKONOS RGB 321). a) área da imagem classificada na COS'90 como Zona industrial (trama azul). b) a mesma área com a	

sobreposição da classificação de Área com dominância de habitação efectuada no estudo (trama vermelha).....	111
Figura 4.35 – Transferências para Zonas com revestimento predominantemente artificializado	111
Figura 4.36 – As Imagens ilustram a transferência de Floresta para Zonas alteradas artificialmente sem vegetação. Fig 4.36 a) extracto de um ortofoto de 1995. Fig. 4.36 b) extracto da imagem fusão do satélite IKONOS de 2000 (RGB 321) sobreposta com a classificação (cor azul) das áreas industriais, efectuada no estudo.	112
Figura 4.37 - Transferências para Zonas alteradas artificialmente sem vegetação.....	112
Figura 4.38 - Classificação da COS'90 sobreposta à imagem IKONOS (RGB 321) em que é visível a área actualmente ocupada pela saibreira e aterro lixeira que em 1990 tinha uma ocupação florestal (cor verde).	113
Figura 4.39 – Conversão da classificação da imagem e da segmentação do nível 3. Fig. 4.39 a) polígonos correspondentes às manchas classificadas, sobrepostos à imagem IKONOS (RGB 321). Fig. 4.39 b) polígonos correspondentes aos objectos imagem.....	114
Figura 4.40 – Tabela contendo os atributos do Mapa de ocupação do Solo	115
Figura 4.41 – Tabela contendo a informação da classificação dos objectos imagem efectuada com a base de conhecimento constituída pelo desenvolvimento hierárquico 2.	115
Figura 4.42 - Extracto do Mapa de Ocupação do solo produzido: Fig. 4.42 a) sem dados auxiliares; Fig. 4.42 b) com dados auxiliares.	116
Figura 4.43 – Fig. 4.43 a) extracto do mapa de ocupação do solo em que são visíveis as classes Área residencial contínua (vermelho escuro) e Área residencial descontínua (cor vermelho claro) e Rede viária(cinzentos claros); Fig. 4.43 b) o mesmo extracto com informação auxiliar correspondente a uma área comercial (azul escuro); Fig. 4.43 c) o resultado da operação de união dos temas Área residencial contínua e Zonas comerciais; Fig. 4.43 d) resultado da operação de extracção (circulo a preto assinala um dos problemas ocorridos).	117
Figura A4.1 – Relações do modelo de dados do Equipamento escolar.	146
Figura A4.2 – Edifícios e limites de propriedade do Equipamento escolar. Os edifícios escolares estão identificados com uma trama azul, os limites de propriedade com traço contínuo azul e o ponto a azul escuro (centróide).	147
Figura A4.4 – Relações do modelo de dados das Actividades económicas.....	150
Figura A4.5 – Resultado de uma consulta simples às actividades económicas sobreposta à imagem IKONOS (RGB 321). A azul estão representadas as actividades ligadas à fabricação de produtos; a vermelho o comércio e a amarelo os serviços.	150
Figura A4.6 – Relações do modelo de dados da Rede viária.	151
Figura A4.7 – Extracto da área de estudo com a rede viária existente sobreposta à imagem IKONOS (RGB 321). Os atributos são relativos ao eixo de via seleccionado (cor verde).	152

INDICE DE QUADROS

Quadro 1.1 - Características dos satélites/sensores actualmente no espaço que captam imagens de grande resolução espacial.	5
Quadro 1.2 - Caracterização dos principais estudos de cartografia temática de ocupação do solo com imagens de grande resolução espacial.	17
Quadro 2.1 - Distribuição da frequência dos valores da máxima probabilidade. Adaptado de Ehlers e Wenzhong (1996).....	38
Quadro 3.1 - Atributos dos objectos obtidos com a segmentação multi-resolução.....	48
Quadro 3.2 - Distribuição da frequência de probabilidade.	58
Quadro 4.1 - Características das imagens utilizadas.	62
Quadro 4.2 - Dados auxiliares.	64
Quadro 4.3 - Resumo da utilidade dos dados auxiliares.	64
Quadro 4.4 - Conteúdo e estruturação da informação do modelo geográfico utilizada no estudo.	66
Quadro 4.5 - Caracterização da correcção geométrica.	67
Quadro 4.6 - Valores radiométricos máximos e mínimos obtidos em duas partes iguais da imagem na banda do azul.....	69
Quadro 4.7 - Resultados da análise estatística dos níveis radiométricos das 4 bandas multiespectrais da banda pancromática da imagem utilizada.	69
Quadro 4.8 - Matriz de correlação entre as 4 bandas da IKONOS 2000.	69
Quadro 4.9 - Nomenclatura de ocupação do solo resultante da análise das classes de informação, existentes na área de estudo, que constituíam o esquema de classificação estabelecido. dúvida.....	71
Quadro 4.10 - Valores dos parâmetros atribuídos na fase da segmentação.	73
Quadro 4.11 - Número de objectos gerados em cada imagem segmentada e tamanho mínimo correspondente.	74
Quadro 4.12 - Número de classes existentes em cada nível de detalhe da nomenclatura estabelecida no estudo, existentes na área de estudo e identificadas na classificação.	88
Quadro 4.13 - Identificação das classes da Nomenclatura de Referência existentes na área de estudo e indicação da sua identificação com base na análise de imagens orientadas por objectos ..	89
Quadro 4.14 - Matriz de confusão e índices de precisão para o mapa de ocupação do solo produzido	91
Quadro 4.15 - Integração da distribuição da frequência dos valores da probabilidade, para a melhor e segunda melhor classificação, obtida nas várias etapas relativamente às classes que constam no mapa final.....	97
Quadro 4.16 - Quantificação para cada classe, que não teve uma total atribuição a uma só classe das classes correspondentes à segunda melhor classificação.....	99
Quadro 4.17 - Avaliação da incerteza das classes identificadas no mapa final.....	100

Quadro A4.1 - Categorias, Tabelas geográficas, Geometria e Tabelas alfanuméricas do Equipamento escolar.....	146
Quadro A4.2 - Categorias, Tabelas geográficas, Geometria e Tabelas alfanuméricas do Equipamento desportivo.....	148
Quadro A4.3 - Categorias, Tabelas geográficas , Geometria e Tabelas alfanuméricas das Actividades económicas.....	149
Quadro A4.4 - Categorias, Tabelas geográficas, Geometria e Tabelas alfanuméricas da Rede viária.	151
Quadro A4.5 - Categorias, Tabelas geográficas e Geometria do Património, Serviços de utilidade pública e Administração local.	152

CAPÍTULO 1 - Introdução

A rapidez com que ocorrem as modificações introduzidas pelo homem em algumas áreas da superfície terrestre, a par com a crescente necessidade em proteger os recursos naturais ou áreas de protecção especial, torna a obtenção e actualização da informação cartográfica de ocupação do solo numa componente crucial para delinear acções de inventariação, gestão e planeamento.

Nas áreas urbanas, são bem evidentes os problemas relacionados com a rápida transformação da cobertura e uso do solo. Aproximadamente 85% da população da Comunidade Europeia vive e trabalha em áreas urbanas (Eurostat, 1993). Esta concentração espacial de actividades humanas tem impactos económicos e ambientais significativos. Por outro lado, informações básicas sobre as áreas urbanas como a sua localização, dimensão, população humana e índices de crescimento estão muitas vezes desactualizadas. A obtenção de informação detalhada e em tempo útil das áreas urbanas é de considerável importância quer para a gestão das actividades urbanas quer para o seu planeamento.

Neste contexto, a classificação do uso do solo a grande escala constitui um documento importante pois evidencia a situação existente antes de qualquer acção de planeamento, servindo também como ferramenta para outro tipo de análises e modelações do espaço urbano. Como exemplo, refira-se a delimitação das zonas morfológicas urbanas a partir da análise espacial dos padrões das várias categorias de uso do solo (Donnay, 1994) e as abordagens de modelação que utilizam novos processos de inferência em que as categorias de uso do solo são relacionadas com uma variável urbana (e.g., população) (Dureau, 1990; Lo, 1995).

1.1 Detecção remota: um instrumento adequado para a cartografia de ocupação do solo de áreas urbanas

A produção de mapas de ocupação do solo pode ser efectuada a partir de dados recolhidos no terreno, fotografia aérea ou imagens de satélite. A detecção remota por fotografia aérea tem sido a fonte de dados mais utilizada nas análises urbanas e na produção de cartografia de ocupação do solo a grande escala, continuando a ser intensivamente usada nos nossos dias. No trabalho desenvolvido no âmbito do programa MURBANDY (*Monitoring Urban Dynamics*) da Comissão Europeia e coordenado pelo *Joint*

Research Center, a fonte de dados mais utilizada para a construção dos mapas de uso do solo, à escala 1:25 000, para várias datas e áreas urbanas europeias (21 cidades e 3 áreas da Europa) foi a fotografia aérea. Portugal, por exemplo, produziu cartografia de uso do solo para 1995 com base nas fotografias orto-rectificadas desse ano, para as cidades do Porto e Setúbal e uma área do Algarve (Caetano *et al.*, 1999).

O método inicialmente utilizado para a produção de cartografia de ocupação do solo recorria à foto-interpretação das provas fotográficas em papel e a processos de foto-restituição analógica. A digitalização por *scanner* de fotografias e ortofotomapas introduziu a interpretação assistida por computador e a fotogrametria digital, o que proporcionou uma melhoria nos processos de trabalho tradicionais.

A utilização de fotografias aéreas na execução de cartografia temática das áreas urbanas a grande escala, necessária nas acções de planeamento, constitui uma alternativa muito dispendiosa pelos recursos humanos que requer e pela morosidade do processo de foto-interpretação. Segundo Moller-Jensen (1990), a cobertura aerofotográfica de grandes regiões é executada com reduzida periodicidade, o que dificulta a actualização das mudanças que ocorrem na ocupação da superfície terrestre. Por outro lado, o método clássico de aquisição da informação temática é muito condicionado pela falta de coerência entre os fotointérpretes.

A partir da década de 70, com o lançamento dos primeiros satélites de observação da Terra, a fotografia aérea começou a ser substituída por imagens de satélite para produzir cartografia de ocupação do solo. As imagens obtidas pelos primeiros satélites/sensores, nomeadamente Landsat TM (*Thematic Mapper*) e SPOT HRV (*High Resolution Visible*), dada a sua resolução espacial, possibilitaram o seu uso na cartografia de ocupação do solo a escalas regionais.

A periodicidade de aquisição das imagens de uma mesma área geográfica em condições de observação semelhantes e em diferentes períodos de tempo, permite a obtenção de registos consistentes multi-temporais particularmente úteis em estudos de detecção de alterações (Baio, 1996). Em termos de análises urbanas, estes estudos são extremamente úteis conforme evidenciam os trabalhos “Estudo do crescimento urbano da Área Metropolitana do Porto (AMP) usando técnicas de Detecção Remota” (Teodoro e Fernandes, 2000) e “Avaliação da dinâmica dos aglomerados urbanos da Área da Grande Lisboa nas últimas duas décadas” a partir de imagens de satélite (Navarro, 1999).

Nos últimos anos, as investigações ao nível da detecção remota urbana têm-se direccionado mais para o uso de imagens multiespectrais obtidas por satélite do que para fotografia aérea, dadas as suas vantagens (Donnay *et al.*, 2001) que, para além das acima mencionadas, se prendem também com a facilidade de obter dados actualizados,

disponibilização em formato digital, dimensão da superfície terrestre abrangida, baixo custo, etc..

Mas as vantagens da detecção remota por satélite não são absolutas e dependem do tipo de imagens, do campo de aplicação e da nomenclatura a utilizar. Na área do planeamento urbano a grande escala, a utilização de imagens do satélite Landsat TM, ou mesmo SPOT, não têm obtido o mesmo nível de resultados como, por exemplo, no planeamento a escalas regionais ou na área das ciências da natureza. Segundo Mesev e Longley (1999), as duas razões principais que têm contribuído para esta situação têm sido a não adequação da resolução espacial dos dados imagem às necessidades do planeamento urbano a grande escala e a limitações dos métodos de extracção da informação a partir de imagens de satélite. Apenas grandes cidades com ruas largas e com uma geometria simples das estruturas puderam ser efectivamente estudadas usando dados SPOT ou Landsat. Um exemplo deste tipo de limitações é evidenciado na realização do trabalho “Estudo do crescimento urbano da Área Metropolitana do Porto (AMP) usando técnicas de Detecção Remota” (Teodoro e Fernandes, 2000) em que foram usadas imagens TM do satélite Landsat 5 de três épocas diferentes (1989, 1992 e 1997).

Segundo Wilkinson (1996), a detecção remota urbana deve ser capaz de fornecer dados que sejam pertinentes no planeamento das áreas urbanas, nomeadamente: (1) delimitação de aglomerados urbanos; (2) caracterização de estruturas urbanas e sua distribuição; (3) principais redes viárias e infra-estruturas relacionadas; (4) indicadores sócio-económicos e várias estatísticas relacionadas com os censos; (5) estruturas urbanas 3D importantes ao nível das telecomunicações (inter-visibilidade); (6) estudos de impacto ambiental; (7) capacidade de monitorizar estas características ao longo do tempo.

O recente lançamento de satélites com sensores ópticos, que recolhem imagens da superfície terrestre de grande resolução espacial, vem disponibilizar uma nova fonte de dados importante, potenciando a sua utilização no contexto das áreas urbanas a grande escala, pois o nível de resolução espacial destas imagens corresponde às escalas de análise entre 1:5 000 e 1:25 000 utilizadas nos projectos de planeamento urbano.

No quadro 1.1 são apresentados os programas dos satélites com sensores que captam imagens com resolução espacial inferior ou igual a 4m e que se encontram operacionais, i.e. EROS A1, IKONOS, QuickBird-2 e SPIN-2. Todos estes satélites têm sensores digitais à excepção do SPIN-2 cujas imagens resultam da digitalização das fotografias captadas pelo sistema de câmaras a bordo de satélites russos.

Estão ainda planeados os lançamentos de mais dois satélites de grande resolução espacial: EROS B e OrbView-3. O programa *Earth Resource Observation Satellite* (EROS) da *ImageSat International* tem previsto o lançamento do segundo satélite, EROS B, em 2003

que disponibilizará imagens pancromáticas e multiespectrais, ambas com uma resolução espacial de 0.85m. O programa OrbView-3, da *OrBimage*, está ainda em fase de desenvolvimento e irá gerar imagens no modo pancromático com 1 m de resolução espacial e no modo multiespectral com 4m de resolução espacial. O satélite irá operar a uma altitude de 470km numa órbita hélio-síncrona. A resolução espectral das bandas fornecidas pelo sensor será equivalente à dos satélites IKONOS e QuickBird-2.

Todos os satélites que adquirem imagens de grande resolução espacial acima referidos, e actualmente operacionais, disponibilizam a informação no modo pancromático e apenas dois (IKONOS e QuikBird-2) disponibilizam a informação no modo multiespectral. A resolução espectral das bandas fornecidas por estes dois satélites é equivalente e o mesmo se perspectiva para os satélites que serão lançados num futuro próximo. As bandas multiespectrais cobrem apenas a zona do visível e do infravermelho próximo, não apresentando bandas no infravermelho médio, ao contrário das imagens Landsat TM. Esta limitação resulta do facto da radiação electromagnética do infravermelho médio ter menos energia e conseqüentemente a quantidade de energia reflectida por pequenas áreas não é suficiente para ser utilizada em detecção remota por satélite. Nas figuras 1.1 e 1.2 apresentam-se imagens do satélite IKONOS com 4m de resolução espacial e Landsat-5TM com 30m de resolução espacial, à escala 1:50 000 e 1:10 000, de uma zona situada no Concelho da Marinha Grande. As imagens apresentadas permitem comparar visualmente a diferença de resolução espacial e o tipo de detalhe dos dados imagem, obtidos por estes dois satélites, a uma escala adequada para estudos regionais e a uma escala maior, mais adequada para estudos locais.

Quadro 1.1 - Características dos satélites/sensores actualmente no espaço que captam imagens de grande resolução espacial.

Satélites	Empresa Responsável	Data de Lançamento	Altitude(Km)	Resolução Espectral (μm)	Resolução Espacial (m)	Resolução Radiométrica (bits)	Resolução Temporal	Área de Cobertura (Km^2)
EROS A1	ImageSat International	5 /12/2000	480	Pancromático (0.5-0.9)	1.8 (Pan) 1 (Pan)	11	2 a 3 vezes por semana	12.5x12.5 ou 6x6
IKONOS	Space Imaging Inc.	24/09/1999	680	Azul (0.45 - 0.52) Verde (0.52 - 0.60) Vermelho (0.63 - 0.69) Infravermelho próximo (0.63 - 0.69) Pancromático (0.45 - 0.90)	1 (Pan) 4 (XS)	8 e 11	3 a 140 dias	11x11 até 11x100
QuickBird-2	DigitalGlobe	18/10/2001	450	Azul (0.45 - 0.53) Verde (0.52 - 0.61) Vermelho (0.64 - 0.72) Infravermelho próximo (0.77 - 0.88) Pancromático (0.45 - 0.90)	0.61 (Pan) 2.4 (XS)	11	1 a 3.5 dias	16.5x16.5 até 16.5x165
SPIN-2	Projecto de Cooperação: Aerial Images Inc., Central Trading Systems Inc., Associação Russa Interbranch SOVINFORMSPUTNICK	A primeira das quatro missões foi lançada a 18/02/98	220	Pancromático (0.51-0.76.)	2 (Pan)	8		40x160

XS - Multiespectral

Pan-Pancromática



Figura 1.1 - Imagem IKONOS e Landsat-5TM do Concelho da Marinha Grande à escala 1:50 000. Fig. 1.1 a) imagem Landsat (30m de resolução espacial), composição RGB 421. Fig. 1.1 b) imagem IKONOS (4m de resolução espacial), composição RGB 321.

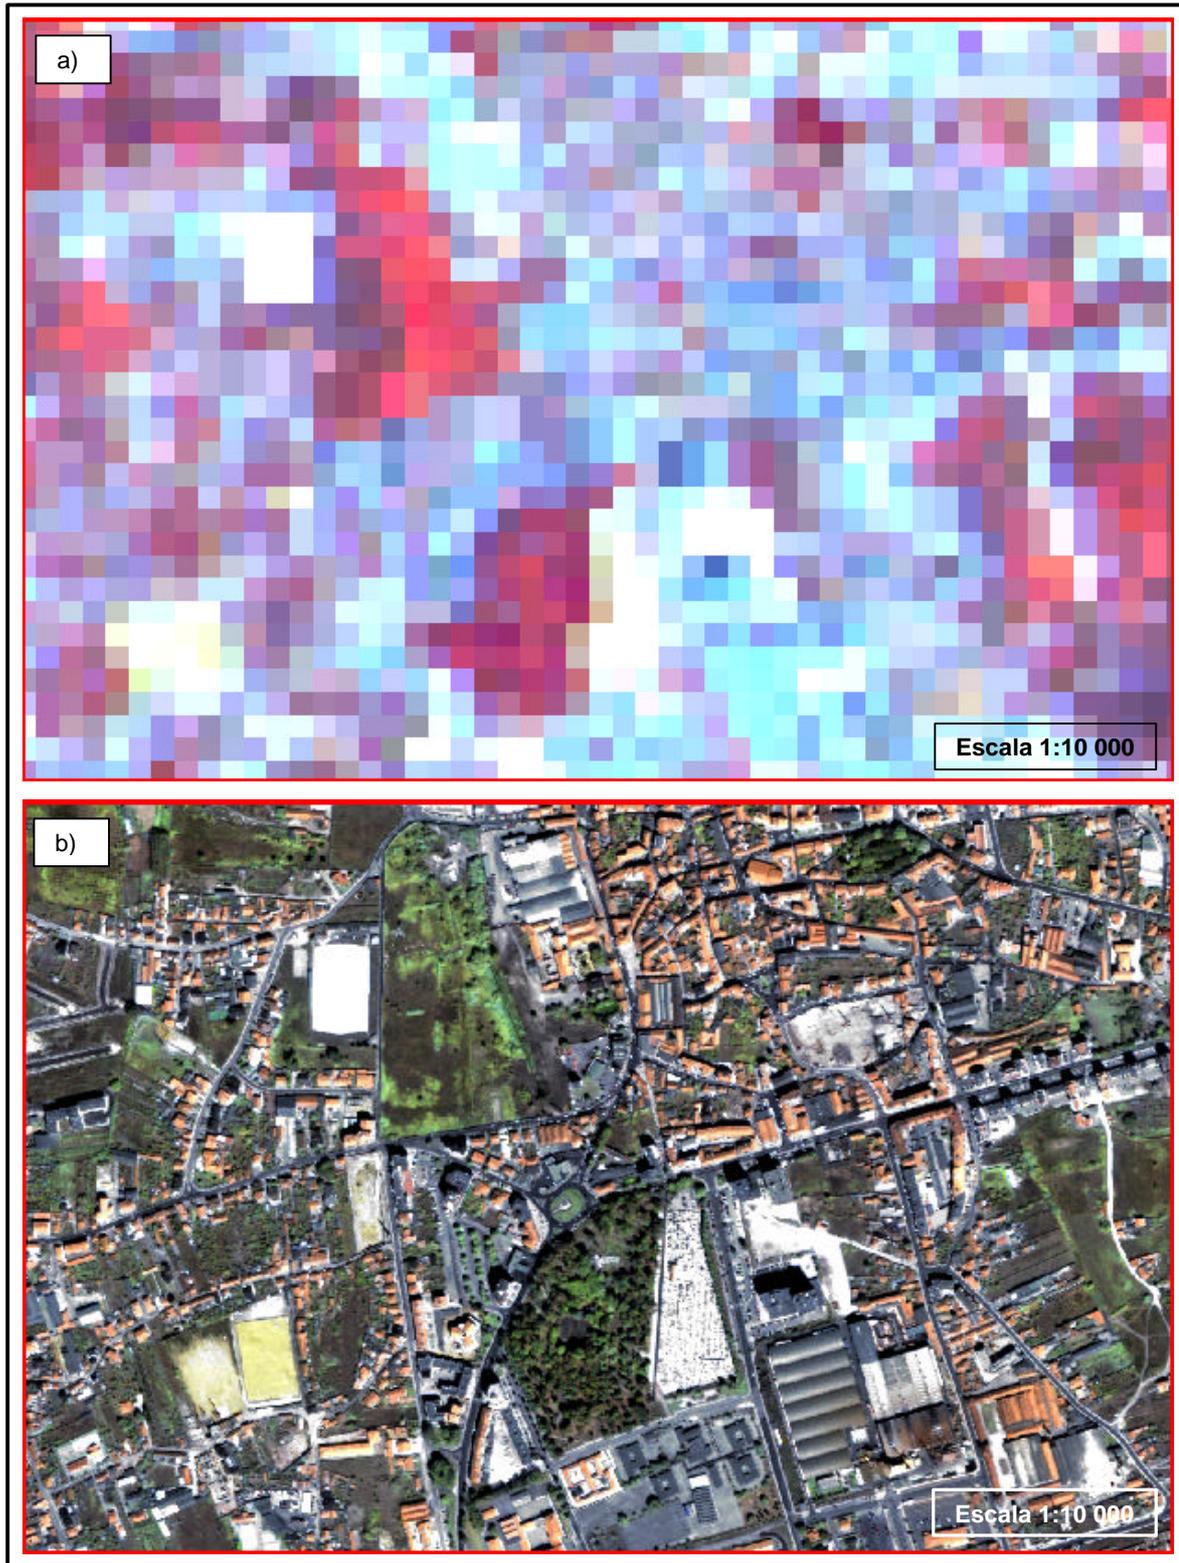


Figura 1.2 - Imagem Landsat-5TM e IKONOS do Concelho da Marinha Grande à escala 1:10 000. Fig.1.2 a) imagem Landsat (30m de resolução espacial), composição RGB 421. Fig.1.2 b) imagem IKONOS (1m de resolução espacial) composição RGB 321.

1.2 Metodologias recentes para exploração de imagens de satélite de grande resolução espacial

Com a colocação em órbita de satélites com sensores ópticos que recolhem imagens da superfície terrestre de grande resolução espacial, como o *Space Imaging IKONOS* e o *QuikBird-2*, abrem-se novas perspectivas em cartografia. A sua recente disponibilização para a comunidade civil veio permitir obter esta informação compatível com as escalas utilizadas na representação cartográfica necessária à gestão e planeamento urbano, a nível municipal.

Embora estas imagens de grande resolução espacial ofereçam benefícios na identificação de elementos individuais das áreas urbanas (casas, arruamentos, etc.), os dados que eles produzem contêm também informação ‘indesejada’ (árvores isoladas, sombras dos edifícios, variações espectrais das várias inclinações dos telhados devido à incidência solar no momento da captação da imagem). A variabilidade espacial inerente à superfície urbana, associada com a complexa gama de actividades humanas, continua a ser um problema na classificação temática de áreas urbanas a partir dos novos dados de detecção remota com os métodos existentes. A utilização desta nova fonte de dados levanta assim novos desafios exigindo o desenvolvimento de novas metodologias e a integração de diferentes métodos de extracção da informação (Donnay *et al.*, 2001).

A maioria das teorias e métodos de análise quantitativa e de processamento foram desenvolvidas para efectuar uma classificação das imagens de satélite ao nível do *pixel* com uma resolução espacial de 10 a 100m (Landsat TM, Landsat MSS, SPOT HRV, SPOT PAN). Este tipo de abordagens não permite explorar e extrair o máximo de informação contida nos novos dados disponibilizados pelos satélites IKONOS e QuikBird ou fotografias aéreas digitalizadas de grande escala. Os detalhes da imagem (e.g., estradas, casas, árvores, sombras), conforme acima referido, tornam-se identificáveis, adquirindo uma certa predominância na resposta espectral de cada *pixel*. Há por isso uma maior necessidade de exploração dos padrões espaciais, com as imagens de grande resolução espacial, do que a já existente com as imagens Landsat TM, Landsat MSS ou SPOT HRV. Alguns dos principais problemas, apontados por diversos autores na extracção da informação a escalas regionais, continuam a existir, nomeadamente: diferentes classes de uso/cobertura do solo apresentarem características espectrais semelhantes e uma mesma classe de uso do solo apresentar características espectrais distintas (e.g., Caetano *et al.*, 1997a). Por outro lado, muitas classes de ocupação do solo não podem ser identificadas ao nível do *pixel*. Por exemplo, a classe de informação “urbano descontínuo”, existente em muitas nomenclaturas, é um arranjo espacial de *pixels* de áreas de construção com *pixels* com vegetação. A sua

identificação tem de ser baseada em análise de padrões espaciais.

Na década de 90, vários estudos foram efectuados e diversos métodos têm sido propostos, por vários autores, para superar estes problemas, entre os quais se destacam o uso de redes neuronais para a análise dos padrões espectrais e espaciais (e.g., Silva e Caetano, 1996), e sistemas periciais que incorporam a informação espectral, textural e contextual (e.g., Kontoes e Rokos, 1996). Como não existiam *softwares* que efectuassem análise de padrões contextuais, os investigadores tiveram necessidade de programar algoritmos que lhes permitissem esse tipo de análises. Santos *et al.* (1996) desenvolveram algoritmos contextuais para a identificação de classes de uso do solo tais como aeroportos e campos de futebol, Cordeiro (1996) desenvolveu algoritmos para identificação de rede viária e Caetano *et al.* (1997 a) desenvolveram algoritmos para discriminar urbano contínuo do descontínuo. Os métodos de classificação por objectos, em oposição à classificação ao nível do *pixel*, facilitam a integração de informação de contexto e permitem a identificação de unidades mínimas de ocupação do solo superiores à unidade do *pixel*, o que se adequa mais à conversão para formato vectorial onde os mapas têm uma determinada unidade mínima de representação de acordo com a escala. Com os métodos automáticos de classificação ao nível do *pixel*, a unidade mínima de representação é o tamanho do *pixel*, o que não é adequado para muitas análises (Nunes *et al.*, 2002), razão pela qual a produção operacional de mapas com imagens de satélite em muitos países é feita recorrendo a análise visual (e.g., CORINE Land Cover).

É necessário continuar a explorar novos métodos alternativos em que a classificação das imagens satélite de grande resolução espacial seja efectuada ao nível dos objectos, ou segmentos, que captem os padrões espaciais dos dados imagem, utilizando classificadores mais flexíveis que permitam a integração não só de dados espectrais para diferenciar as classes, mas também de dados de forma, textura, relações de vizinhança e informação de contexto. No fundo, que permitam aproximar mais o tratamento automático de imagens ao processo utilizado na foto-interpretação.

Recentemente foi criado o primeiro *software* de processamento de imagem em que se encontra implementado um método de análise de imagens orientada por objectos (eCognition), sendo a classificação das imagens efectuada não ao nível do *pixel* mas a partir de objectos imagem.

Estes novos métodos (análise orientada por objectos) abrem também uma nova porta à integração da detecção remota com os Sistemas de Informação Geográfica (SIG), pois permitem que os dados estruturados num SIG possam ser utilizados directamente como informação auxiliar no processo de classificação. Muitas das abordagens de integração de SIGs com detecção remota têm envolvido sistemas de processamento de

imagem separados dos SIG, em que o resultado das imagens classificadas ou é convertido no formato vectorial e importado para um SIG vectorial, ou transferido para um SIG capaz de manipular dados *raster*, integrados com mapas de dados vectoriais (Janssen *et al.*, 1990). Segundo Hinton (1999), um sistema plenamente integrado deveria envolver uma única unidade de *software* com processamento combinado, sem necessidade de conversão de formatos, permitindo a transferência de informação entre dados imagem e a base de dados vector. Com o *software* de processamento eCognition 2.1 é possível a integração dos dados de detecção remota e SIGs, sem necessidade de conversões. Por outro lado, a informação estruturada num SIG pode ser utilizada directamente como uma banda adicional, na fase de segmentação, para gerar os objectos imagem ou ser utilizada como fonte de informação auxiliar no processo de classificação dos objectos gerados. Distinguem-se ainda dois *softwares* recentes: *Laserscan IGIS* e *Feature Analyst*.

O *Laserscan IGIS* incorpora tecnologia de base de dados orientada por objectos para extrair informação a partir de dados imagem. Quando o processamento da imagem e as facilidades dos SIG se combinam num sistema totalmente integrado, os dados podem ser usados para dar assistência à classificação da imagem e as estatísticas de imagem *raster* dentro de vectores podem ser utilizadas como critérios para análise vectorial (Hinton, 1999).

O *Feature Analyst* é uma extensão para Arcview 3.2 e permite um processamento combinado, em que as funcionalidades do SIG são utilizadas para auxiliar o processo de classificação. Os dados extraídos das imagens de detecção remota são obtidos directamente no formato vectorial e os dados estruturados no SIG podem ser utilizados como informação auxiliar. Esta ferramenta constitui mais um passo para a completa integração entre estas duas áreas.

O benefício destes desenvolvimentos está apenas a começar, muitas opções possíveis têm sido discutidas quanto ao futuro de SIGs integrados, incluindo ferramentas de modelação e integração com sistemas inteligentes (Hinton, 1999).

1.3 Cartografia temática com imagens de grande resolução espacial: estado da arte

Nesta secção apresentam-se os resultados de uma exaustiva pesquisa de literatura em cartografia temática de ocupação do solo com imagens de satélite de grande resolução espacial. Apesar do objecto de estudo nesta tese estar relacionado com áreas urbanas, são referidos também alguns trabalhos em áreas não urbanas, já que as metodologias de análise de imagem podem ser semelhantes. No quadro 1.2 apresenta-se uma caracterização sumária dos principais estudos analisados.

Cartografia temática de áreas urbanas

Aplin *et al.* (1999), efectuaram um projecto de investigação com o objectivo de desenvolver um sistema automático operacional para classificar o uso do solo a uma escala local, a partir de imagens satélite de grande resolução espacial, que pudesse mais tarde ser expandido a uma escala nacional. A área de teste, com aproximadamente 5x8km², era composta por uma variedade de usos do solo rurais e urbanos. As classes de uso do solo foram escolhidas de acordo com as especificações do *National Land Use Stock System* (NLUSS) e foi efectuada uma classificação ao nível da parcela (*per-field classification*). Foram utilizadas imagens do *Compact Airborne Spectrographic Imager* (CASI) para simular as imagens multiespectrais de satélite IKONOS e utilizaram-se dados vectoriais digitalizados referentes ao levantamento do terreno (*Land-Line coverage*) e Sistemas de Informação Geográfica. A metodologia seguiu três etapas: pré-processamento das imagens CASI, classificação ao nível do *pixel* e classificação ao nível da parcela. A classificação ao nível do *pixel* foi efectuada usando o classificador da máxima verosimilhança. O resultado obtido foi integrado com a informação do levantamento e efectuada uma re-classificação ao nível da parcela. Para proceder a esta re-classificação, foram calculadas as classes de uso modais (a classe de uso dominante) no interior de cada parcela (polígono), sendo então atribuída a cada parcela, integralmente, a classe dominante no seu interior. O resultado inicial da classificação ao nível do *pixel* foi de 63.08%, tendo ocorrido confusão espectral com algumas classes de vegetação. Como a classificação ao nível da parcela é dependente da classificação ao nível do *pixel* esta foi também baixa, 59.23%. Uma das soluções para melhorar a precisão da classificação ao nível do *pixel* foi considerar apenas áreas de treino para as classes que ocupavam áreas proporcionalmente semelhantes na área de estudo. A precisão da classificação ao nível do *pixel* passou para 78% e para a classificação ao nível da parcela obteve-se uma precisão de 86%, mais 8% de precisão que na classificação ao nível do *pixel* (Aplin *et al.*, 1999). Um dos problemas apontados pelos autores e que não foi possível resolver deve-se a problemas de ajustamento geométrico entre os dados imagem (*raster*) e os limites das parcelas (vectors).

Bauer e Steinnocher (2001), utilizaram imagens pancromáticas e multiespectrais IKONOS para produzir cartografia de ocupação do solo de uma parte da área metropolitana de Viena. O objectivo consistia em formalizar o procedimento da interpretação visual no sentido de automatizar o processo de produção de mapas de uso do solo e avaliar se as imagens IKONOS poderiam ser utilizadas como fonte de dados alternativa à fotografia aérea. A nomenclatura de referência utilizada foi a nomenclatura definida no inventário de uso do solo de Viena composta por 42 classes. A abordagem utilizada no processamento foi constituída por duas fases: (1) obter as principais coberturas do solo existentes na imagem;

(2) analisar a informação obtida num contexto espacial para distinguir os diferentes usos do solo presentes. Para a obtenção do mapa de cobertura do solo foi efectuada uma classificação assistida usando o classificador da máxima verosimilhança tendo sido utilizada, como máscara, a rede viária estruturada num Sistema de Informação Geográfica. Para construir o sistema de regras a partir do qual foi efectuada a classificação do uso do solo foi utilizado o método de análise orientado por objectos. Com este método foi possível distinguir 11 classes de uso. O estudo não faz referência à forma como foi efectuada a avaliação do mapa produzido e qual a precisão obtida. Os autores referem apenas que os resultados obtidos, quando comparados com o mapa do uso do solo existente de Viena, apresentaram um elevado grau de correspondência para estas classes. Problemas ocorreram quando as classes de uso do solo que se pretendiam distinguir tinham uma estrutura e uma cobertura do solo semelhante mas que diferiam nas suas características funcionais. Segundo Bauer e Steinnocher (2001), os dados IKONOS apresentaram uma boa aptidão para a obtenção de mapas de uso do solo urbano constituindo uma alternativa à fotografia aérea para actualizar bases de dados cartográficas. Relativamente à abordagem utilizada, a experiência com o algoritmo de classificação orientada por objectos mostrou que a qualidade da classificação do uso do solo foi bastante condicionada pela qualidade do mapa inicial da cobertura do solo obtido pelo método tradicional de classificação automática.

Meinel *et al.* (2001) utilizaram também imagens multiespectrais do satélite IKONOS. O objectivo do estudo consistiu em avaliar a quantidade de informação que era possível extrair das imagens de grande resolução espacial de áreas urbanas, aplicando diferentes metodologias. O trabalho apresentado não menciona a nomenclatura utilizada. A área de estudo situou-se em Dresden, na Alemanha, cobrindo uma área de 2.4 km x 2.4 km. Para extrair a informação foram testadas 2 metodologias: (1) classificação ao nível do *pixel*, (2) análise orientada por objectos. Em ambas as abordagens a classificação é efectuada a partir de uma base de conhecimento estruturada de forma hierárquica. Para efectuar a classificação ao nível do *pixel* foi utilizado o módulo *ExpertClassifier* do *IMAGINE 8.4* (ERDAS) tendo sido usadas as quatro bandas do satélite IKONOS, um índice de vegetação (NDVI) e a componente principal de segunda ordem. Para aplicar a segunda abordagem foi utilizado o *software* eCognition 2.1 (*Definiens*) tendo sido usado um índice de vegetação (NDVI) e a fusão da imagem pancromática com a multiespectral (efectuado com um procedimento baseado em componentes principais). Ambos os métodos deram origem a precisões semelhantes, 89.6%. A segunda abordagem, como permitiu incorporar relações de vizinhança e informação da forma, tornou possível a correcta identificação dos rios e a discriminação de um maior número de classes como campos desportivos e edifícios. O primeiro método permitiu extrair 11 classes e o segundo método 13 classes. Houve também

diferenças nas áreas que ficaram por classificar, 0.42% no primeiro método e 0.07% no segundo. Segundo Meinel *et al.* (2001), apesar das imagens IKONOS disponibilizarem imagens com uma maior resolução espacial, não é possível extrair todas as coberturas /uso do solo com um nível de precisão satisfatório a partir apenas dos dados imagem.

Dois outros estudos, em que foram também utilizadas imagens IKONOS e aplicado o método de análise orientada por objectos, para extrair informação das imagens de grande resolução espacial, foram realizados por Hofmann (2001a) e Demetre e Panos (2002).

Hofmann (2001a) apresenta um estudo para detectar construções ilegais (barracas clandestinas) na Cidade do Cabo (África do Sul). Na extracção da informação foi utilizado o método de análise orientada por objectos acima referido e um modelo de superfície como informação adicional. A metodologia consistiu em efectuar duas segmentações da imagem com diferentes escalas. A identificação do uso do solo dos segmentos/objectos foi depois efectuada utilizando classificação *fuzzy*. Na fase de pré-processamento foi efectuada também a fusão da imagem pancromática com a multiespectral com um procedimento baseado em componentes principais. Segundo Hofmann (2001a), embora este método altere os valores espectrais da imagem quando se trabalha com pequenos objectos, pode ajudar a melhorar a definição de limites importantes dos objectos. O estudo salienta a importância da utilização da informação adicional do modelo de superfície para obter resultados fiáveis referindo que não é possível detectar as entidades físicas das áreas correspondentes às construções ilegais (pequenas barracas, ou abrigos, construídas com diversos materiais) apenas com dados das imagens IKONOS. As áreas correspondentes às construções clandestinas foram detectadas satisfatoriamente embora fosse difícil detectar as barracas individualmente (Hofmann, 2001a). O estudo não refere a precisão da classificação efectuada.

Demetre e Panos (2002) efectuaram uma análise das áreas verdes urbanas de uma área com 2048mx2048m situada nos arredores de Atenas, Grécia. Na fase de pré-processamento foi efectuada a fusão das bandas multiespectrais e pancromática com o método *Local Mean Matching* (LMM). A metodologia consistiu também em efectuar duas segmentações da imagem com diferentes escalas. A classificação dos segmentos foi efectuada utilizando classificação *fuzzy*. Com a primeira segmentação geraram-se segmentos mais pequenos com forma semelhante e tamanho idêntico o que facilitou a identificação de áreas com vegetação densa, pouca vegetação e sem vegetação. No processo de classificação destas classes foi utilizado um índice de vegetação (*Scaled MSAVI*). Com a segunda segmentação da imagem foram classificados grandes espaços que correspondiam a áreas de construção e áreas com vegetação, com o objectivo de criar um mapa temático da densidade de áreas verdes urbanas. O mapa final resultou da

combinação das duas classificações. A avaliação dos resultados indicou que a detecção e a avaliação quantitativa dos espaços verdes urbanos foi obtida com uma precisão satisfatória. A avaliação da qualidade dos resultados obtidos é efectuada apenas com base na análise da incerteza mas não são apresentados, em termos quantitativos, a distribuição espacial para cada classe da incerteza da classificação.

Cartografia temática de áreas não urbanas

A equipa de investigação do *Mid Atlantic – Regional Earth Science Application* (RSAC) da Universidade de Maryland utilizou imagens do satélite IKONOS para obter mapas com a informação de corredores de vegetação, ao longo de linhas de água (*Map Riparian Forest Buffers*). O objectivo era avaliar as capacidades das imagens para extrair este tipo de informação pois tradicionalmente era utilizada fotografia aérea para obter mapas florestais, mas esta abordagem era morosa e dispendiosa. A utilização das imagens Landsat TM constituía outro meio de obter esta informação mas havia limitações devido à sua resolução espacial. A classificação com imagem Landsat TM apenas permitia detectar corredores com largura superior a 90 m. No estudo foi efectuada uma classificação assistida usando o classificador da máxima verosimilhança e utilizada informação auxiliar da rede hidrográfica da área de estudo. Em torno das linhas de água foi criado um *buffer* de 30.48m (100ft) e a percentagem de cobertura florestal foi calculada para pequenas sub-bacias hidrográficas. As imagens multiespectrais do satélite IKONOS com 4m de resolução espacial já permitiram obter informação de corredores de vegetação ao longo de linhas de água com cerca de 12m de largura. O estudo apresentado não faz referência à avaliação da qualidade, refere apenas que o trabalho permitiu demonstrar a eficácia da metodologia utilizando dados IKONOS e actualmente está a ser implementada em toda a região de Montgomery (Mid-Atlantic RESAC, 2002).

Um outro projecto, ainda a decorrer, realizado por Heyman, da Universidade de Oregon, tem como objectivo demonstrar que as imagens de grande resolução espacial do satélite IKONOS podem ser usadas para identificar habitats de espécies florestais na região semi-árida do Oeste Americano. Numa primeira fase, a espécie estudada foi a faia (*Populus tremuloides*). A área de teste situou-se no estado de Oregon. A informação foi extraída a partir das imagens multiespectrais tendo sido usada informação da textura e um sistema baseado em regras de interpretação construídas a partir do conhecimento humano da foto-interpretação de imagens de detecção remota, relativo a este tipo de espécie e do seu meio ambiente. Para proceder à classificação foi desenvolvido um sistema automático utilizando técnicas de processamento com base em conhecimento e conceitos de

classificação por objectos tendo sido utilizado o modulo *ExpertClassifier* do *IMAGINE* 8.4 (ERDAS). A segmentação inicial foi efectuada com base num limiar (*thresholding*). Foram classificadas três tipos de categorias: áreas com uma cobertura de faias inferior a 25%, entre 25% e 90%, e superior a 90%. Para comparar os resultados com os métodos tradicionais foi também aplicada, a uma sub-área, classificação assistida usando o classificador do paralelepípedo. Com o método aplicado foi possível obter não só uma boa delimitação mas também um sistema flexível em que o utilizador pode aceder aos dados de acordo com a percentagem de confiança dos resultados da classificação (Heyman, 2002).

Franklin *et al.* (2001) efectuaram um estudo para avaliar se a análise da estrutura e da composição das espécies florestais poderia ser obtida, com a precisão necessária, a partir de dados imagem multiespectrais de grande resolução espacial (1m) recorrendo a análise espacial da textura (*spatial co-occurrence texture analysis*) e uma classificação assistida usando o classificador da máxima verosimilhança. Foram utilizadas imagens do CASI para simular as imagens multiespectrais de satélite IKONOS. A área de estudo situou-se no *Fundy Midel Forest* no sudoeste de New Brunswick. A metodologia utilizada foi a seguinte: (1) classificação das assinaturas espectrais utilizando o classificador da máxima verosimilhança; (2) repetição da classificação utilizando apenas os dados da textura; (3) repetição da classificação combinando a medição da textura com a assinatura espectral para cada classe. Dos vários testes efectuados alterando a dimensão da vizinhança, a que conduziu a medições mais estáveis da textura foi a de 19x19 *pixels*. Com a classificação utilizando apenas dados espectrais obteve-se uma precisão de 54%, com apenas dados de textura 70% e com a combinação de dados textura e dados espectrais 75%. Ao efectuar a fusão das espécies com estrutura e composição semelhante, criando categorias de classes com base na dominância/co-dominância das espécies, as precisões obtidas foram de 70% utilizando apenas dados espectrais, 76% utilizando apenas dados de textura e 70% com a combinação de dados textura e dados espectrais. Segundo Franklin *et al.* (2001), a aptidão dos dados imagem de grande resolução espacial, para classificar estruturas e composições de espécies florestais, pode contribuir para o desenvolvimento de novos métodos para produzir inventários florestais.

No quadro 1.2 apresenta-se uma caracterização dos principais estudos de cartografia de ocupação do solo com imagens de grande resolução espacial acima referidos.

Analisando os projectos descritos conclui-se que, à excepção dos trabalhos efectuados por Aplin *et al.* (1999), Meinel *et al.* (2001) e Franklin *et al.* (2001), não houve uma avaliação da qualidade dos mapas produzidos o que dificulta a extrapolação dos métodos para outras áreas. O trabalho apresentado por Meinel *et al.* (2001), embora refira a precisão global da informação obtida, é vago na apresentação dos resultados

desconhecendo-se como é que foi efectuada essa avaliação, que classes é que foram identificadas, qual a precisão por classes, etc. e, por outro lado, não é feita uma exposição detalhada da metodologia adoptada. Por outro lado, os estudos não utilizam, na sua maioria, uma nomenclatura standard e, conforme se pode constatar no quadro 1.2, nenhum dos projectos refere a área mínima de representação da informação ou a escala do mapa que se pretende produzir.

Alguns dos estudos com imagens de grande resolução espacial são análises exploratórias em que se pretende estudar apenas as potencialidades de um método para extrair, de imagens de grande resolução espacial, um tipo específico de informação (Hofmann, 2001a; Demetre e Panos, 2002). O trabalho desenvolvido por Aplin *et al.* (1999) embora constitua um estudo sistemático, para produção de cartografia de ocupação/uso do solo (efectuado com o objectivo de mais tarde ser expandido a uma escala nacional), a metodologia aplicada é dependente da classificação ao nível do *pixel* e da existência de informação vectorial auxiliar que muitas vezes não se encontra disponível.

Podemos assim concluir que metodologias e estudos sistemáticos para produção de cartografia/uso do solo com imagens de grande resolução espacial continuam a ser um campo de investigação.

Quadro 1.2 - Caracterização dos principais estudos de cartografia temática de ocupação do solo com imagens de grande resolução espacial.

	Imagem	Objectivos	Número de classes identificadas	Escala	Área Mínima	Precisão
Aplin <i>et al.</i> (1999)	Simulação de IKONOS (Imagens CASI)	Cartografia de ocupação/uso do solo urbano e rural	13	Não refere	Não refere	86%
Steinnocher e Bauer (2001)	IKONOS	Cartografia de ocupação/uso do solo de áreas urbanas	11	Não refere	Não refere	Não refere
Meinel <i>et al.</i> (2001)	IKONOS	Cartografia de ocupação/uso do solo de áreas urbanas	13	Não refere	Não refere	89.6%
Hofmann (2001a)	IKONOS	Identificação de construções clandestinas	Não refere	Não refere	Não refere	Não refere
Panos e Demetre (2002)	IKONOS	Identificação e análise dos espaços verdes urbanos	Não refere	Não refere	Não refere	Não refere
Heyman (2002)	IKONOS	Identificação de habitats de espécies florestais	Não refere	Não refere	Não refere	A decorrer a validação do trabalho
A equipa de investigação do Mid-Atlantic RSAC	IKONOS	Corredores de vegetação ao longo de linhas de água	Não refere	Não refere	Não refere	Não refere
Franklin <i>et al.</i> (2001)	Simulação de IKONOS (Imagens CASI)	Análise da estrutura e composição das espécies florestais	30	Não refere	Não refere	75%

1.4 Objectivos do estudo

O principal objectivo do estudo apresentado nesta tese de Mestrado consiste em desenvolver e testar uma metodologia que permita extrair informação das imagens de grande resolução espacial do satélite IKONOS, com o fim de obter um Mapa de Ocupação do Solo a grande escala de forma automática. Para extrair a informação a partir dos dados de grande resolução espacial aplica-se uma abordagem que se baseia na análise de imagens orientada por objectos, classificação *fuzzy* ao nível dos objectos imagem e integração de análise contextual. Com a metodologia baseada em análise de imagens orientada por objectos, a importante informação semântica necessária para interpretar as imagens de grande resolução espacial do IKONOS não é representada ao nível do simples *pixel*, mas no significado dos objectos da imagem e nas suas relações mútuas. A classificação das imagens de satélite é, assim, efectuada utilizando não só dados espectrais para diferenciar as classes, mas também dados da forma, textura, relações de vizinhança, hierarquia e contexto.

Numa primeira fase serão extraídos os objectos imagem que captam os padrões espaciais dos dados utilizando um método de segmentação, recentemente desenvolvido e designado por segmentação 'multi-resolução' (*multiresolution segmentation*).

Numa segunda fase é construída uma base de conhecimento estruturada sob a forma de uma hierarquia de classes. O processo de classificação é baseado na lógica *fuzzy*, o que permite a integração de um largo espectro de diferentes características de objectos como os valores espectrais, forma, textura, informação de contexto e possibilita a análise da incerteza temática.

Faz-se ainda uma análise, em termos quantitativos, da distribuição espacial da incerteza da classificação para cada classe e efectua-se a sua representação visual. A representação visual da incerteza tem como objectivo permitir que o utilizador possa visualizar os dados de acordo com a percentagem de confiança dos resultados da classificação.

Ao aplicar esta nova metodologia, na extração da informação temática das imagens de grande resolução espacial do satélite IKONOS, de forma automática, pretende-se estudar as suas limitações e capacidades como método alternativo às tradicionais abordagens de classificação ao nível do *pixel*.

O estudo descrito nesta dissertação, aplicando este tipo de abordagem para extração de informação a partir dos dados imagem do IKONOS, constitui um dos primeiros a nível internacional e o primeiro a nível nacional. No ESIG' 2001 (VI Encontro de Utilizadores de Sistemas de Informação Geográfica) foram apresentados resultados

preliminares deste trabalho (Gonçalves *et al.*, 2001).

1.5 Organização do estudo

O estudo encontra-se estruturado em 5 capítulos em conformidade com os objectivos referidos anteriormente.

No presente Capítulo introduziu-se o tema, referindo a importância da cartografia de ocupação do solo de áreas urbanas, a evolução dos métodos inerentes à sua produção, a importância das imagens de satélite de grande resolução espacial como fonte de dados e a necessidade de desenvolvimento de novas metodologias. Apresentaram-se ainda trabalhos realizados sobre cartografia de ocupação do solo com imagens de grande resolução espacial e definiram-se os objectivos deste estudo e a sua organização.

No Capítulo 2 é efectuado um breve desenvolvimento teórico sobre as várias etapas inerentes ao processo produtivo da cartografia de ocupação do solo de forma automática e é apresentada uma revisão de literatura sobre a visualização da incerteza temática.

No Capítulo 3 é descrita a metodologia desenvolvida para extrair a informação das imagens de grande resolução espacial do satélite IKONOS, com o fim de obter Mapas de Ocupação do Solo de forma automática, recorrendo à análise de imagens orientada por objectos, classificação fuzzy e análise de incerteza temática.

No Capítulo 4 apresenta-se a implementação da metodologia a imagens IKONOS a uma área do Concelho da Marinha Grande. Previamente serão descritos os dados utilizados: imagens do satélite IKONOS, dados auxiliares e suas características, área de estudo e *software* adoptado para a realização do estudo. Na parte final do capítulo, apresenta-se a representação gráfica da incerteza temática e a avaliação da dinâmica do Mapa de Ocupação do Solo produzido por comparação com a Carta de Ocupação do solo de 1990 (COS'90), obtida por análise visual de fotografia aérea.

No Capítulo 5 são tecidas algumas considerações sobre a eficácia da análise de imagem orientada por objectos para resolver determinados problemas, relativamente aos tradicionais procedimentos de extracção da informação baseados no *pixel*. São igualmente referidas as potencialidades das imagens IKONOS como suporte de informação para obtenção, de forma automática, de cartografia de ocupação do solo.

CAPÍTULO 2 – Produção de cartografia de ocupação do solo com imagens satélite: das metodologias tradicionais às mais recentes

Neste capítulo é efectuada uma descrição sumária das várias etapas que constituem o processo de produção da cartografia de ocupação do solo com imagens de satélite. Aborda-se com maior pormenor as metodologias e técnicas desenvolvidas para extracção da informação temática, uma vez que tem sido a área do processamento de imagens onde tem ocorrido mais investigação e, também, pelo facto deste estudo se dedicar a um dos métodos mais recentes para extracção de informação de ocupação do solo. Apresenta-se ainda um outro tópico que tem sido pouco abordado mas que é de grande importância: a incerteza temática e a sua visualização.

2.1 Etapas comuns ao processo produtivo de cartografia de ocupação do solo

O processo produtivo de cartografia de ocupação do solo, a partir de imagens de satélite, envolve geralmente as seguintes etapas: (1) pré-processamento; (2) transformação de bandas; (3) extracção da informação temática; (4) integração de informação auxiliar e (5) avaliação da qualidade dos mapas.

No início de um estudo com imagens multiespectrais, é fundamental proceder a uma análise exploratória dos dados para averiguar a sua qualidade o que facilita posteriormente todo o processo de análise e cálculo. A imagem é então pré-processada para reduzir distorções dos dados provocadas por factores ambientais e/ou pelos próprios satélites/sensores. O pré-processamento envolve operações que permitem reduzir distorções geométricas e radiométricas das imagens. Várias técnicas de realce de imagens podem também ser aplicadas aos dados rectificadas para melhorar a sua interpretação e a aplicação de processamentos posteriores, nomeadamente: a aplicação de operadores multi-banda que possibilitam a redução da redundância de informação presente nos dados originais, diferenciação de determinados elementos da imagens, realce de fronteiras entre diversos usos do solo. A extracção da informação temática constitui a última etapa do processamento. Para melhorar os resultados da classificação pode ser integrada informação adicional. Na fase final do processo produtivo é efectuada a avaliação do mapa produzido.

Pré-processamento: correcção geométrica e radiométrica

As imagens obtidas por satélite possuem distorções geométricas e radiométricas que foram introduzidas durante a sua aquisição. Em qualquer estudo que utilize este tipo de dados é essencial efectuar um conjunto de operações e procedimentos para corrigir, ou pelo menos minimizar, estas distorções.

As distorções geométricas são causadas durante o processo de aquisição dos dados pelo sensor e podem dever-se a vários factores como: (1) a variação de altitude e atitude; (2) velocidade do satélite; (3) curvatura da Terra; (4) movimento de rotação da Terra durante o período de tempo de aquisição da imagem.

As distorções geométricas que são previsíveis, provocadas por factores conhecidos, são denominadas de *sistemáticas* e são corrigidas aplicando modelos matemáticos determinados a partir do conhecimento dos factores que provocam a distorção. Em geral quando se compra uma imagem, esta já vem corrigida das distorções sistemáticas. As distorções provocadas pela variação de altitude e atitude do satélite são denominadas *distorções não sistemáticas ou acidentais* e normalmente são corrigidas através de modelos empíricos, construídos com base em pontos de controle distribuídos por toda a imagem.

Os pontos de controle são pontos dos quais se conhece as suas coordenadas cartográficas, em relação a um dado sistema de projecção cartográfica, e as suas coordenadas imagem (posição em linha e coluna na imagem) permitindo assim a associação de coordenadas cartográficas à imagem. Estes pontos são escolhidos de forma a que a sua posição no terreno seja facilmente identificável e bem conhecida e que, na imagem, permitam também uma fácil identificação. Este processo de correcção é vulgarmente designado por geo-referênciação.

Para referenciar correctamente uma imagem, relativamente a um dado sistema de projecção cartográfica, é necessário efectuar uma transformação matemática que permita recolocar cada *pixel* da imagem original, com as coordenadas (x,y), na posição correspondente na imagem rectificada, com coordenadas (M,P). Para isso recorre-se a equações polinomiais, para determinar os parâmetros de transformação de coordenadas pelo Método dos Mínimos Quadrados, com o objectivo de calcular as correcções a efectuar. Depois de aplicada a transformação, a precisão do modelo é avaliada pelo erro médio quadrático.

As novas posições dos *pixels* podem não coincidir com nenhuma das posições da imagem original sendo necessário proceder à reamostragem da imagem, ou seja, determinar um novo valor para os níveis radiométricos (NR) a atribuir a cada *pixel* da imagem corrigida. A reamostragem pode ser efectuada utilizando o método do vizinho mais

próximo, o método da interpolação bilinear e o método da interpolação cúbica. O método usualmente escolhido é o do vizinho mais próximo pois tem a vantagem de não alterar os valores dos NR_s na imagem rectificada. Este método consiste em atribuir o NR do *pixel* mais próximo na imagem original não rectificada. Os outros dois métodos de interpolação calculam o NR do *pixel*, através de uma média ponderada inversamente proporcional ao quadrado da distância com os *pixels* mais próximos (Lillesand e Kiefer, 1994).

Para definir quais as correcções radiométricas necessárias a um determinado estudo com imagens satélite, é importante compreender as fontes de distorção radiométrica. As fontes de distorções radiométricas podem dividir-se em duas categorias: as relacionadas com o sensor e as relacionadas com a própria imagem (Teillet, 1986). As distorções relacionadas com o sensor podem dever-se a um mau funcionamento dos instrumentos de medida ou podem estar associadas com o processo de conversão da radiância num sinal numérico. As distorções relacionadas com a própria imagem devem-se a factores atmosféricos e geo-radiométricos, nomeadamente topografia, condições de iluminação e ângulo de observação.

Basicamente o efeito da atmosfera é devido aos fenómenos de absorção e dispersão. Os constituintes da atmosfera (gases, água, aerossóis, etc.) interagem com a radiação electromagnética, proveniente do sol e da reflexão ou emissão dos objectos da superfície terrestre, através de fenómenos de absorção e dispersão. Estes efeitos podem diminuir a capacidade de interpretação e de extracção da informação a partir de imagens obtidas por sensores orbitais. A absorção reduz a quantidade de energia disponível num determinado comprimento de onda, enquanto a dispersão redistribui essa energia alterando a sua direcção de propagação. A dispersão actua sobretudo nos comprimentos de onda compreendidos entre 0.4 µm e 0.7µm (zona do visível) e a absorção actua sobretudo nos comprimentos de onda superiores a 0.7 µm (zona do infravermelho próximo).

Um outro efeito atmosférico que modifica a quantidade de energia recebida nos sensores é a radiância de percurso (*path radiance*). A radiância de percurso corresponde a uma quantidade de energia que é adicionada à radiação proveniente da superfície e que é detectada pelo sensor. Pode ser devida a radiação solar que é dispersa pela atmosfera e que pode alcançar o sensor sem nunca ter atingido a superfície.

Em áreas planas, a mais importante distorção radiométrica em detecção remota deve-se ao efeito da atmosfera. Em áreas montanhosas, para além deste factor, o efeito da topografia e do tipo de cobertura do solo constituem uma das principais distorções radiométricas. O efeito topográfico faz com que o mesmo tipo de ocupação do solo tenha radiâncias diferentes, numa mesma banda, em função das características topográficas do

local onde se encontra. Enquanto em superfícies planas a geometria entre as posições relativas do sol, sensor e a superfície é constante para todos os *pixels*, em zonas de relevo acidentado há alterações de *pixel* para *pixel*, sendo necessário modelar estas variações espaciais (Caetano, 1995). Como na distorção radiométrica deve ser tomada em consideração a interacção dos efeitos geo-radiométricos (topografia, iluminação e ângulo de observação) com os efeitos atmosféricos, a correcção em zonas com relevo acentuado torna-se ainda mais complexa (Teillet, 1986). Nas superfícies planas, se a atmosfera tiver um efeito uniforme nos dados pode inferir-se que é uniforme em toda a área de estudo (Kaufman, 1984), na áreas montanhosas não se pode considerar este pressuposto. Mais ainda, em zonas com relevo acentuado, existe uma fonte extra de irradiância, i.e., a radiância que é reflectida pelas áreas vizinhas adjacentes, a qual é insignificante em áreas planas podendo, portanto, ser desprezada.

A quantidade de radiância que chega a cada ponto da superfície proveniente do Sol, i. e., irradiância directa, é função do coseno do ângulo de incidência (ângulo entre o feixe de radiação solar e a normal à superfície). Em áreas planas, o valor do ângulo de incidência é constante para todos os pontos da superfície e igual ao ângulo zenital solar, enquanto que em áreas montanhosas o valor do ângulo é variável, podendo existir zonas que não recebam luz solar directa se o ângulo de incidência for superior a 90^0 (efeito de *self-shadow*). A irradiância solar directa constitui apenas uma das componentes da irradiância total que um *pixel* recebe. A outra componente mais importante é designada por irradiância difusa e resulta da radiação difundida pela atmosfera que alcança a superfície. A irradiância difusa captada pelos sensores é também afectada pelo declive e exposição de um dado *pixel* e pela topografia adjacente.

Ao utilizar a detecção remota para caracterizar quantitativamente os objectos da superfície, interessa que essa informação esteja somente relacionada com características do próprio objecto. A única maneira de remover todos os factores que afectam o sinal registado no sensor que não estão relacionados com a cobertura do solo, é converter os NR, que incorporam os efeitos atmosféricos e geo-radiométricos, para unidades de reflectância da superfície. A reflectância é a proporção de irradiância que é reflectida pela superfície e dependente apenas das características da superfície do terreno.

Caetano (1995) sistematiza o processo de conversão dos níveis radiométricos para reflectâncias em três etapas: (1) conversão radiométrica, (2) conversão para reflectâncias aparentes e (3) correcção atmosférica (passagem para reflectâncias de superfície).

A conversão de NR_s para reflectâncias de superfície é um processo complexo e envolve modelos que requerem o conhecimento de vários parâmetros atmosféricos no

momento da aquisição da imagem (e.g., espessura óptica da atmosfera, tipos de aerossóis presentes) que na maior parte das vezes não estão disponíveis. Por essa razão têm sido desenvolvidas outras técnicas que não requerem a conversão dos NR_s em reflectâncias. Por exemplo, um método alternativo, utilizado em estudos multitemporais, é a normalização temporal de imagens em que o objectivo não é eliminar os efeitos dos factores externos em todas as imagens mas igualá-los tornando as imagens comparáveis. Nos estudos unitemporais de áreas planas, a eliminação das distorções radiométricas nem sempre é necessária, mas em áreas de relevo acentuado existem distorções que necessitam sempre de ser reduzidas, i.e. o efeito da topografia. Caetano (1995) refere dois grupos de técnicas que reduzem o efeito topográfico: (1) transformação da própria imagem (e.g., quocientes de bandas espectrais); (2) procedimentos baseados em modelos, que relacionam os valores da radiância medidos pelos sensores com os principais indicadores de topografia (e.g., modelos digitais de terreno). De salientar que estas técnicas alternativas são baseadas em transformações de imagens e alteram os valores iniciais dos *pixels*. Um outro grupo de técnicas que tem sido desenvolvida para melhorar a precisão da classificação dos dados de detecção remota em áreas de relevo acentuado, consistem na integração de dados auxiliares na análise de imagens (e.g., modelos digitais de terreno, declives, convexidade, exposição). Este tipo de técnicas, em vez de reduzir o efeito topográfico, adiciona mais informação à imagem para compensar o erro existente nos dados de detecção remota. Com este tipo de técnicas os NR_s não são transformados.

Pode-se concluir que a correcção radiométrica necessária num determinado estudo depende da topografia da área em estudo, da uniformidade da atmosfera e de ser um estudo em que se utiliza apenas uma imagem ou uma série multitemporal.

Transformação de bandas

Para realçar a informação que se pretende extrair dos dados imagem, podem-se associar às técnicas usadas na produção de cartografia de ocupação/uso do solo várias técnicas de transformação de bandas como, por exemplo, a análise de componentes principais, índices de vegetação ou análises de textura, etc..

Os índices de vegetação são uma combinação de operações aritméticas entre bandas espectrais, efectuadas para permitir a quantificação relativa da vegetação e da biomassa presente numa imagem. A maior parte do índices de vegetação baseia-se nas grandes diferenças de reflectância que a vegetação verde apresenta na banda vermelha do visível e do infravermelho próximo. Vários índices de vegetação foram utilizados para estimar o índice de área foliar, percentagem de coberto vegetal, altura das

plantas, biomassa, etc. (Perry, 1984). Os índices de vegetação mais comuns são o *Ratio Vegetation Index* (RVI), que resulta do quociente entre o vermelho e o infravermelho próximo, e o *Normalized Difference Vegetation Index* (NDVI) que resulta do quociente entre a diferença das bandas e a soma dessas mesmas bandas.

A textura está relacionada com a variabilidade e arranjo dos NR_s numa dada vizinhança. Vários parâmetros têm sido propostos para avaliar a textura de dados imagem nomeadamente parâmetros estatísticos tais como a variância, desvio padrão, coeficientes de assimetria dos NR_s. As transformadas de textura têm sido utilizadas, no processo de classificação, como uma banda adicional às bandas espectrais (Jensen e Toll, 1982; Pedley e Curran, 1991).

A análise de componentes principais é uma técnica que permite reduzir a redundância dos dados originais das diferentes bandas de uma imagem multiespectral. Esta transformação pode ser aplicada como uma operação de realce a efectuar antes da interpretação visual dos dados ou como um procedimento de pré-processamento antecedendo a classificação automática dos dados (Lillesand e Kieffer, 2000). Uma aplicação da utilização de componentes principais de imagens de detecção remota é a detecção de variações de ocupação do solo em imagens multitemporais (Baio, 1996; Richards e Xiuping, 1999).

Extracção da informação

Com o objectivo de encontrar uma metodologia que possibilite a extracção da informação das imagens de satélite, de forma automática, capaz de reduzir as limitações inerentes aos métodos de interpretação visual, tem-se assistido ao desenvolvimento de várias teorias e métodos de análise quantitativa e de processamento, destacando-se os métodos lineares, morfologia matemática, análise contextual, aplicação de inteligência artificial e, mais recentemente, a análise de imagem orientada por objectos.

Pode considerar-se que os vários métodos desenvolvidos constituem três tipos de abordagens na análise dos dados multiespectrais: (1) classificação ao nível do *pixel* apenas com base na informação espectral; (2) classificação ao nível do *pixel* combinada com análise contextual; (3) análise de imagem orientada por objectos.

Apesar dos consideráveis desenvolvimentos conseguidos, a precisão dos mapas temáticos obtidos a partir de dados de detecção remota é muitas vezes considerada baixa para o seu uso operacional. Existe uma série de razões como sejam a natureza das classes, a resolução espectral e radiométrica dos dados de detecção remota e os métodos usados na extracção da informação (Foody, 1999). A classificação das imagens não é

um processo simples e linear pois nem sempre os objectos têm a resposta espectral esperada devido, por exemplo, tanto a condições de iluminação como a condições atmosféricas (Baio,1996). O facto do uso do solo, nomeadamente nas áreas urbanas, ser definido mais em termos da sua função que da sua forma, torna as relações entre uso do solo e as respostas espectrais gravadas nas imagens muito complexa e indirecta.

Muitas das aplicações de processamento de imagens, apesar do seu desenvolvimento técnico, não fazem uso de conceitos espaciais (Blaschke *et al.*, 2000). As técnicas de classificação automática tradicionais classificam o uso do solo apenas com base na distribuição espectral dos *pixels* da imagem. Com os progressos conseguidos nos últimos anos ao nível da detecção remota, uma variedade de sensores disponibilizam, agora, imagens de grande resolução espacial. Estudos realizados por vários autores têm feito notar que o aumento da resolução espacial pode conduzir a maiores problemas, tornando difícil a extracção da informação do uso do solo com base unicamente em informação espectral. Esta nova fonte de dados, conforme referido na secção 1.2 do Capítulo 1, levanta novos desafios e exige novas técnicas de extracção da informação.

Vários grupos de investigadores apresentam como método alternativo a integração, no processo de classificação, de informação auxiliar (e.g., Aplin *et al.*, 1999). Mason *et al.* (1988), sugerem que dados auxiliares podem ser incorporados antes, durante e após a classificação. Vários estudos procedem primeiro a uma classificação da cobertura do solo utilizando uma classificação ao nível do *pixel* antes de integrarem dados auxiliares e aplicarem algoritmos contextuais. Aplin *et al.* (1999) efectuaram uma classificação ao nível da parcela com imagens de grande resolução espacial (simulação das imagens do satélite IKONOS) denotando que este tipo de abordagem contribui positivamente para a classificação de imagens de detecção remota de alta e média resolução espacial pois permite obter bons resultados em termos de precisão.

Contudo, para além de aspectos metodológicos, uma outra questão se coloca nomeadamente quando a informação auxiliar não está disponível ou necessita de ser actualizada. Segundo Blaschke *et al.* (2000), uma solução é a segmentação da imagem. A visão humana geralmente divide primeiro as imagens em áreas ou objectos homogéneos caracterizando-os posteriormente; a nossa percepção do conteúdo da imagem é principalmente baseada em objectos (Blaschke *et al.*, 2000). A segmentação assemelha-se à percepção humana e à forma como extraímos visualmente a informação.

Métodos de classificação

Segundo Jensen (1996), a classificação de dados multiespectrais pode ser efectuada usando uma variedade de algoritmos que incluem: (1) classificação usando uma abordagem assistida ou não assistida (*hard classification*); (2) classificação usando lógica *fuzzy* (*soft classification*) e/ou (3) uma abordagem híbrida muitas vezes envolvendo o uso de informação auxiliar. Pertencendo a uma nova geração de classificadores, também considerados como métodos avançados de reconhecimento ou classificação de padrões, para além da classificação baseada na lógica *fuzzy* acima referida, incluem-se também as redes neuronais.

A classificação não assistida envolve algoritmos que agrupam, de forma automática, os *pixels* da imagem apoiando-se no princípio de que os valores radiométricos de uma determinada classe de ocupação do solo são relativamente próximos quando comparados com outras classes. O classificador separa automaticamente agregados (*clusters*) de *pixels* extraíndo as várias classes espectrais presentes na imagem. Posteriormente o analista terá que fazer a correspondência entre estas classes espectrais e as classes de ocupação do solo da nomenclatura que definir. Uma das vantagens deste tipo de classificadores é que identificam todas as classes espectrais da imagem. Algumas dessas classes poderiam não ser aparentes para o analista ao aplicar a classificação assistida. Existem vários algoritmos que podem ser usados para determinar as classes espectrais presentes na imagem sendo o *K-means* um dos mais utilizados (Lillesand e Kiefer, 1994).

A classificação assistida exige, à partida, um conhecimento de um conjunto de classes de ocupação do solo bem definidas. Este método envolve duas fases distintas: treino e classificação. Na fase de treino, identificam-se as amostras representativas das várias classes que se pretendem identificar e efectua-se uma análise estatística de cada classe que melhor descreva os atributos espectrais de cada tipo de ocupação do solo a representar. Esta fase necessita de um conhecimento geográfico da área de estudo, de dados e trabalho de campo, uma vez que exige a delimitação prévia, efectuada pelo operador, de áreas suficientemente representativas da variabilidade espectral de cada classe. Os resultados da classificação dependem fundamentalmente do número total de *pixels* das áreas de treino e da sua localização e dispersão na área de estudo (Lillesand e Kiefer, 1994).

Os métodos de classificação assistida mais comuns na detecção remota, referidos na bibliografia mais recente por métodos tradicionais, são o *Classificador da máxima verosimilhança*, *Classificador da distância mínima* e o *Classificador do paralelepípedo*.

Apesar dos métodos de classificação assistida tradicionais serem muito aplicados,

nem sempre são apropriados para a obtenção de mapas a partir de dados de detecção remota. Foody (1999) identifica relativamente ao classificador da máxima verosimilhança, um dos métodos mais utilizados, alguns problemas nomeadamente: (1) sendo um classificador paramétrico, os dados são assumidos como tendo uma distribuição normal, o que muitas vezes não acontece; (2) é necessário um grande número de áreas de treino; (3) não permite o uso directo, na fase de classificação, de informação disponível (e.g., a partir de um Sistema de Informação Geográfica); (4) é muito exigente em termos computacionais, sendo relativamente lento (um problema que pode ser significativo com o volume de dados obtidos a partir dos sensores remotos de grande resolução espacial). Um outro problema apontado por vários autores, relativamente aos métodos convencionais, é a dificuldade de lidarem com o problema dos *pixels* mistos (*mixed-pixel*).

Uma vez que os resultados de uma classificação com métodos convencionais podem falhar para representar apropriadamente a cobertura do solo, têm sido procuradas abordagens alternativas que permitam classes múltiplas ou parciais de pertença (Wang, 1990) e que consigam lidar com o problema dos *pixels* mistos.

Classificação *fuzzy*

As técnicas de classificação *fuzzy* têm sido um dos focos de investigação. A classificação *fuzzy* utiliza o conceito de conjuntos *fuzzy* em que uma entidade (um *pixel*) pode apresentar qualquer cenário possível de pertença desde uma pertença total a uma classe, até uma pertença dividida entre todas as classes, ou seja, pertenças parciais a mais do que uma categoria (Jensen, 1996; Foody, 1999). A classificação *fuzzy* é uma técnica que, basicamente, transforma valores característicos em valores *fuzzy*, entre '0' e '1', indicando o grau de pertença a uma classe específica. Isto permite um conhecimento da mistura de classes para cada objecto imagem e a criação de mapas que guardam a incerteza que ocorre na discriminação contínua dos tipos de cobertura do solo. Segundo Baatz *et al.* (2000), esta é uma das vantagens deste tipo de classificação. O maior grau de pertença a uma classe determina a classificação final.

A classificação baseada na lógica *fuzzy*, ou lógica difusa, foi estruturada em 1965, pelo Dr. Zadeh da Universidade da Califórnia, para tratar e representar incertezas. A lógica *fuzzy* torna-se importante na medida em que o mundo em que vivemos não é constituído por factos absolutamente verdadeiros ou falsos. A lógica *fuzzy* é uma abordagem matemática para quantificar a incerteza de acontecimentos. Distingue-se da lógica booleana por permitir a utilização de um intervalo entre os limites 0 e 1 e não apenas estes. A ideia básica é substituir os dois acontecimentos lógicos 'sim' e 'não' por um intervalo contínuo

[0,1], em que o '0' significa 'não' e o '1' significa 'sim' e todos os valores entre '0' e '1' representam um maior ou menor estado de 'sim' ou 'não'.

Assim, a lógica *fuzzy* é usada para simular o pensamento humano, tendo também em conta regras linguísticas. Tem como objectivo modelar o modo aproximado de raciocínio humano, tentando imitar a habilidade humana para tomar decisões racionais num ambiente de incerteza e imprecisão. É, deste modo, uma técnica inteligente que fornece um mecanismo para manipular informações imprecisas (como conceitos de pequeno, alto, bom, muito quente, frio) que permite inferir uma resposta aproximada para uma questão baseada num conhecimento que é inexacto, incompleto ou não totalmente confiável. Devido às suas características intrínsecas, é capaz de incorporar tanto o conhecimento objectivo (a partir de dados numéricos) quanto o conhecimento subjectivo (a partir de informações linguísticas). É aplicada em sistemas de controle e de suporte à decisão onde a descrição do problema (regras de produção) não pode ser feita de forma precisa podendo ser também aplicada na análise de dados e reconhecimento de padrões.

Os conjuntos *fuzzy* são caracterizados pelas funções de pertença (*membership function*). Matematicamente, um conjunto *fuzzy* A em x é descrito pela função de pertença como um conjunto par tal que

$$A = \{X, m_a(x)\}, \quad x \in X$$

em que $m_a(x)$ é o grau de pertença de x em A e, $x \in X$ significa que x faz parte do universo em discussão. O valor de pertença $m_a(x)$ pode variar num qualquer intervalo de valores mas usualmente, por convenção e simplicidade, é considerado o intervalo contínuo [0,1] com uma transição gradual desde uma total pertença '1' a uma não pertença '0' (Power *et al.*, 2001).

A classificação, introduzida por Wang (1990), designada por classificação *fuzzy* assistida é semelhante ao método de classificação da máxima verosimilhança. A diferença é que o vector média *fuzzy* e as matrizes de covariância são desenvolvidos a partir da estatística das médias ponderadas das áreas de treino. Em vez de delinear áreas de treino que são puramente homogéneas, pode ser usada uma combinação de áreas de treino puras e mistas. Os pesos das classes de treino *fuzzy* são definidas conhecendo as misturas de vários tipos de características. Na classificação de um *pixel* é então atribuído um grau de pertença em relação à sua atribuição a uma determinada classe de informação. Por exemplo, a classe vegetação pode incluir um *pixel* com um grau de 0.68 da classe de "floresta", 0.29 de "ruas" e 0.03 de "relva" (o total dos graus de todas as classes potenciais tem de ser igual a 1) (Lillesand e Kiefer, 2000).

Segmentação

Nenhum dos vários métodos de classificação ao nível do *pixel* parece satisfazer todas as necessidades para produzirem resultados precisos e robustos a partir dos dados de detecção remota (Blaschke *et al.*, 2000). Uma das fortes motivações para o desenvolvimento de técnicas para a extracção de objectos imagem deve-se ao facto de os dados imagem possuírem características de textura que são negligenciadas nos métodos mais comuns de classificação. Por outro lado, em muitos casos, a informação necessária para interpretar uma imagem não é representada ao nível do simples *pixel*, mas no significado dos objectos da imagem e nas suas relações mútuas.

A segmentação da imagem consiste na subdivisão da imagem em zonas, ou regiões, homogéneas e uniformes em função de um determinado atributo da imagem. O nível de subdivisões depende do tipo de problema que se quer resolver. Posteriormente pode ser associada informação a cada uma das regiões formadas, para ser utilizada na sua classificação.

Existem vários métodos de segmentação das imagens em função dos dados utilizados para a sua partição que podem classificar-se em: métodos de segmentação baseados num limiar (*thresholding* ou *seuillage*), se o atributo usado é a intensidade dos níveis radiométricos; métodos de segmentação texturais se o atributo é a textura; métodos de segmentação por regiões, se utilizam propriedades espaciais para a partição da imagem.

Os algoritmos para segmentação que usam, como atributo, os valores dos níveis radiométricos baseiam-se geralmente na descontinuidade ou similaridade (Gonzalez e Woods, 1992). Na primeira categoria, a partição da imagem é baseada em mudanças abruptas dos níveis de cinzento. Incluem-se neste conjunto os métodos de segmentação por detecção isolada de pontos e por detecção de linhas e contornos numa imagem. Os algoritmos baseados na similaridade incluem os métodos de segmentação por limiarização e segmentação por regiões.

A segmentação baseada num limiar utiliza o nível de cinzento dos *pixels* da imagem para distingui-los. É particularmente útil na segmentação de objectos contidos sobre um contraste de fundo bem definido na imagem e realiza-se usualmente para criar máscaras para análises posteriores. A regra de utilização tem como característica a selecção de um valor limite (limiar) ou um intervalo de valores de amplitude compatíveis com a intensidade luminosa dos objectos que se pretendem extrair. O resultado da segmentação é uma imagem binária em que os *pixels* cujos níveis de cinzento pertencem ao patamar definido são considerados como pertencendo ao objecto e tomam o valor 1 e os restantes são considerados como não pertencendo ao objecto e tomam o valor 0. A escolha dos valores

do limiar pode ser obtida a partir da análise do histograma da imagem. Este método apresenta algumas limitações pois não funciona bem em imagens com iluminação não uniforme e baixo contraste (Gonzalez e Woods, 1992).

Relativamente aos métodos de segmentação por regiões destacam-se o método por crescimento de regiões (*region growing*) e o método por divisão e fusão (*region splitting and merging*) (Gonzalez e Woods, 1992). A segmentação por regiões utiliza propriedades espaciais da imagem para a sua partição e obedece a uma série de condições ou critérios: a segmentação tem que ser completa, ou seja, todos os *pixels* têm que pertencer a uma região; os pontos de uma região têm que ser conexos; as regiões têm que ser disjuntas (a intersecção de duas regiões é um conjunto vazio); todos os *pixels* de uma região têm que ter a mesma intensidade (Gonzalez e Woods, 1992).

O método por crescimento de regiões consiste em agrupar *pixels*, ou sub-regiões, em regiões maiores. O procedimento começa por, a partir de um pequeno conjunto de *pixels* da imagem (*seed pixels*), agrupar *pixels* vizinhos que tenham propriedades semelhantes (e.g., nível de intensidade, textura ou cor). Um dos problemas deste método é a escolha inicial dos *pixels* (*seed pixels*) que representem convenientemente regiões de interesse e a selecção de propriedades adequadas para incluir os *pixels* nas várias regiões durante o seu processo de crescimento. A figura 2.1 ilustra o método por crescimento de regiões.

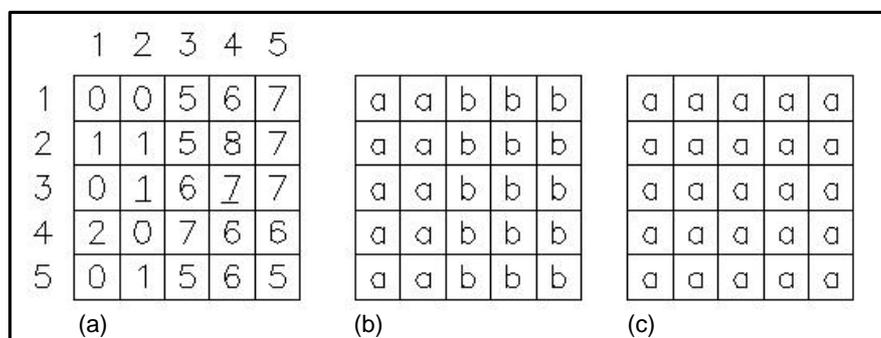


Figura 2.1 - Método por crescimento de regiões utilizando *pixels* conhecidos à partida: (a) matriz da imagem original cujos valores correspondem aos níveis de intensidade. Os *pixels* conhecidos a partir dos quais se inicia o processo correspondem, na matriz (a), à posição (3,2) e (3,4); (b) segmentação resultante, usando como critério de agregação a diferença, em valor absoluto, dos níveis de intensidade dos *pixels* vizinhos inferior a 3 NR; (c) segmentação resultante usando uma diferença em valor absoluto inferior a 8 NR. Adaptado de Gonzalez e Woods (1992).

No método por divisão e fusão, a imagem é dividida de forma arbitrária num conjunto de regiões disjuntas e, em seguida, procede-se à fusão ou divisão das regiões de forma a que os critérios supra referidos se verifiquem. Uma das formas de dividir a imagem inicial baseia-se numa representação em *Quadtree*. Um bloco quadrado é dividido em

quatro quadrados iguais. Os quatro quadrados contíguos são fundidos num único quadrado se forem homogêneos em relação a determinados critérios como sejam: os *pixels* têm que pertencer a uma região; os pontos de uma região têm que ser conexos; as regiões têm que ser disjuntas; todos os *pixels* de uma região têm que ter a mesma intensidade (Gonzalez e Woods, 1992). Se não há homogeneidade, esse quadrado continua a ser dividido e assim sucessivamente; o processo é interrompido quando não for possível efectuar mais nenhuma fusão ou divisão. Na figura 2.2 é apresentado o método de segmentação por divisão e fusão.

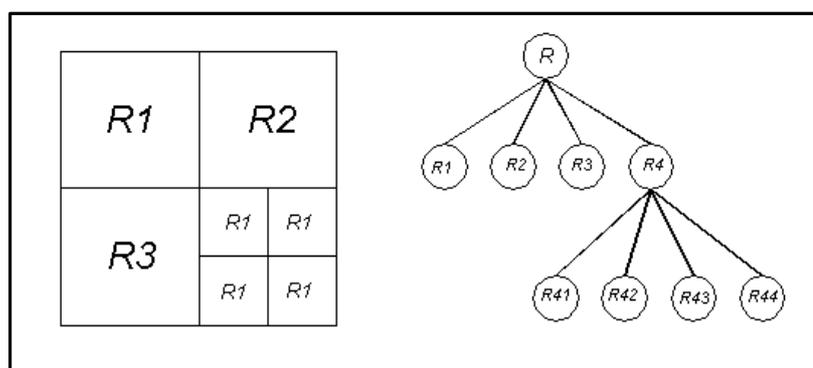


Figura 2.2 - Segmentação por divisão e fusão. Adaptado de Gonzalez e Woods (1992).

No âmbito da morfologia matemática, Beucher e Lanttuéjoul (1979) introduzem um algoritmo de segmentação, designado por transformação por linha de separação de águas (*watershed transform*), que estabelece uma analogia com um processo de inundação de uma superfície topográfica. A utilização da transformação *watershed* apresenta um problema, ou constrangimento, que se prende com a sobre-segmentação da imagem e que está directamente relacionada com o elevado número de mínimos contidos na imagem original que podem ser motivados por ruído da própria imagem. A aplicação de filtros alternados abertura - fecho e do gradiente morfológico é uma das formas de ultrapassar este problema (Pina, 1998).

Apesar de existirem vários métodos de segmentação, só algumas abordagens permitem obter resultados convincentes quando aplicados no processamento de dados de detecção remota de áreas urbanas. Pesaresi e Bianchin (2001) aplicaram um método de segmentação utilizando um gradiente morfológico para extrair informação estrutural dos dados imagem SPOT-HRV pancromáticos relativa a áreas de construção na região do Veneto, Itália. A precisão obtida foi de 90% na classificação de áreas construídas. Para obtenção destes resultados foi utilizado um procedimento de fusão entre a informação estrutural com a classificação da informação espectral dos dados imagem Landsat TM.

Os métodos de morfologia matemática têm sido também aplicados com sucesso

para extracção de informação de rede viária (Destival, 1987; Serendo, 1989; Wang *et al.*, 1996; Cordeiro, 1996). Métodos de segmentação que incorporem a textura têm permitido obter bons resultados na extracção da informação florestal (Lobo, 1997; St-Onge e Cavayas, 1997; Franklin *et al.*, 2001). St-Onge e Cavayas (1997) utilizaram um método de segmentação textural e obtiveram uma precisão de 80% na identificação de classes florestais a partir de imagens de grande resolução espacial.

Baatz e Schape (2000) propõem um novo algoritmo de segmentação designado por segmentação multi-resolução (*multiresolution segmentation*). Este método permite extrair objectos homogéneos das imagens em diferentes escalas, tendo em conta critérios de cor, forma e textura. O método baseia-se na técnica de fusão de regiões começando por cada *pixel* formar um objecto ou região (Baatz e Schape, 2000). A fusão dos objectos contíguos é decidida com base em critérios de homogeneidade local que produzam um mínimo de acréscimo da heterogeneidade. É um processo de *clustering* ao qual está subjacente um procedimento de optimização que minimiza a heterogeneidade dos objectos imagem resultantes. Os objectos contíguos são fundidos num único objecto se a heterogeneidade do objecto resultante da fusão não ultrapassar um valor máximo de heterogeneidade espectral. Consequentemente, o tamanho dos objectos imagem resultantes da fusão depende do valor atribuído a esse parâmetro. O parâmetro que determina a heterogeneidade máxima é, por esta razão, designado por parâmetro escala (Baatz e Schape, 2000). O processo pára quando não houver mais objectos para fundir. A segmentação em objectos abre uma oportunidade para aplicar vários conceitos geográficos no processamento das imagens. O método permite a extracção de objectos homogéneos da imagem em qualquer resolução que se pretenda e pode ser aplicado a uma variedade de dados. Funciona com um número arbitrário de bandas ou canais simultaneamente e está especialmente adaptado para dados textura ou com baixo contraste, como sejam os dados *radar* (*Radio Detection and Ranging*) ou imagens de alta resolução espacial (VHR, *Visible High Resolution*). Trabalhos de investigação sobre as potencialidades do método (e.g., Schiewe *et al.*, 2001) têm demonstrado que permite obter bons resultados na extracção de informação urbana a partir de imagens de grande resolução espacial, embora ainda apresente limitações (situações de sombra e distinção entre rede viária e áreas envolventes).

Integração de informação auxiliar

A classificação automática de dados de detecção remota, para produção de mapas de ocupação/uso do solo apenas com base na informação espectral, muitas

vezes não produz resultados suficientemente fiáveis para que os mapas obtidos possam ser usados de forma operacional.

No processo de foto-interpretação o analista tem ao seu dispor: (1) conhecimento sobre o solo, geologia, vegetação, hidrologia e a geografia da área, (2) capacidade de, visualmente, compreender e interpretar a cor, textura, contrastes, sombras, dos dados imagem, (3) capacidade de usar toda esta informação para compreender o contexto de condições locais e associação de fenómenos, (4) conhecimento histórico da área (Mason *et al.*, 1988). Segundo Jensen (1996), 95% das classificações automáticas de imagens de detecção remota utilizam, para atingir o mesmo objectivo, apenas uma única variável, a cor.

Numerosos investigadores têm tentado melhorar a precisão e qualidade dos mapas produzidos por classificação automática incorporando informação adicional (e.g., Hutchinson, 1982; Trotter, 1991) que pode ser derivada de dados auxiliares. Dados auxiliares são todo o tipo de informação espacial, ou não espacial, que pode ser importante no processo de classificação de imagens mas que não está contida nelas. Inclui por exemplo, hidrologia, rede viária, limites administrativos, modelo de superfície, dados derivados de modelos digitais de terreno (e.g., declive, exposição), dados censitários, dados estatísticos com representação geográfica (Jensen, 1996). Ao integrar dados adicionais aos dados de detecção remota é importante uma boa precisão planimétrica dos dados auxiliares e a correcta geo-referênciação dos dados auxiliares à imagem.

Várias abordagens têm sido usadas para incorporar informação auxiliar no processo de classificação. Estas incluem a introdução de dados antes, durante e depois do processo de classificação. A inclusão de dados adicionais antes do processo de classificação pode ser efectuada, por exemplo, para possibilitar a divisão da imagem em estratos que podem então ser processados separadamente (Jensen, 1996). O objectivo é reduzir a variabilidade espectral das diferentes categorias que se pretendem discriminar. No estudo “Avaliação da dinâmica dos aglomerados urbanos da Área da Grande Lisboa nas últimas duas décadas” a rede viária foi, em conjunto com a imagem SPOT pancromática, utilizada para estratificar a área de estudo em áreas urbanas e rurais (Navarro, 1999). Uma outra abordagem utilizada por vários autores para permitir introduzir novas variáveis na classificação, tem sido a integração de informação, durante o processo de classificação, como banda adicional a juntar às bandas espectrais originais (e.g., Jones *et al.*, 1988; Franklin e Wilson, 1992). A inclusão de informação auxiliar como método de melhoramento pós-classificação tem sido também utilizada para solucionar vários tipos de ambiguidades entre classes espectrais permitindo a re-classificação da informação que, devido à semelhança espectral, é difícil de discriminar (e.g., Janssen *et al.*, 1990). Este tipo de

método envolve a aplicação de regras aos resultados iniciais da classificação através de algoritmos de análise espacial (e.g., Santos *et al.*, 1996; Caetano *et al.*, 1997a). A integração de conhecimento no processo de classificação, através do desenvolvimento de algoritmos, no fundo, é uma forma de aproximar o sistema de análise ao método utilizado na foto-interpretção.

Avaliação da qualidade da classificação

Os mapas resultantes das várias etapas de processamento acima descritas têm de ser sujeitos a um processo de validação para que seja atribuído um índice de fidelidade aos resultados obtidos. O método mais usual para avaliar a qualidade dos dados obtidos, no processo de classificação, envolve a determinação de uma matriz, designada por matriz de confusão ou matriz de erro, que confronta esses mesmos resultados com dados de referência para os quais se conhece a verdadeira classificação. Os dados utilizados nas áreas de teste, para validar a qualidade da classificação, devem ser diferentes dos dados usados na fase de treino. As áreas teste devem ser uniformes e distribuídas por toda imagem.

A matriz de erro é uma tabela de contingência em que os elementos da diagonal representam o número de indivíduos correctamente atribuídos à sua classe e os elementos fora da diagonal representam classificações incorrectas. As classificações incorrectas podem ser divididas em dois tipos: erros de omissão, erros de comissão. Os erros de omissão correspondem a indivíduos que pertencendo a uma determinada classe não foram incluídos nela. Os erros de comissão correspondem a indivíduos que foram classificados numa determinada classe mas que na realidade pertencem a outra.

O processo de validação dos mapas produzidos é composto pelos seguintes passos: (1) extracção de uma amostragem da população; (2) recolha da verdadeira classificação na informação de referência relativa às áreas amostradas; (3) cálculo da matriz de erro e respectivos índices de precisão (Congalton e Green, 1999).

2.2 Visualização gráfica da incerteza

A avaliação da qualidade da informação temática obtida no processo de classificação de imagens satélite é efectuada fundamentalmente através da determinação de uma matriz de erro, conforme acima referido. Embora este tipo de informação relativamente à qualidade dos dados seja importante, não permite a visualização da distribuição espacial da incerteza da classificação.

Um importante aspecto da análise da incerteza é a sua visualização para melhorar a análise, ou entendimento dos dados, por parte do utilizador. Com efeito, a visualização é uma técnica eficiente e apropriada para tornar informações complexas mais compreensivas. O sistema de processamento humano da informação possui uma forte acuidade para a visualização e uma habilitação para reconhecer estruturas e relacionamentos. As estruturas espaciais são mais fáceis de expressar e compreender através de representações gráficas ou cartográficas, constituindo um rápido meio de comunicação (Beard, 1998). Estas características tornam os métodos gráficos adequados para a compreensão humana dos aspectos complexos da qualidade dos dados espaciais.

Com o crescente uso de dados geográficos e dos Sistemas de Informação Geográfica, há uma crescente exigência relativamente à qualidade de informação inerente aos dados usados e aos resultados obtidos no processamento desses dados (Faiz e Boursier, 1994). Um problema que tem vindo a ser estudado é a quantificação de erros ou de incerteza da informação das análises SIG que requerem a combinação de dados heterogéneos. Para proceder às operações de análise espacial, inerentes a um determinado estudo, existe a necessidade de lidar com vários tipos de dados provenientes de várias origens como sejam dados SIG vectoriais, dados *raster* de detecção remota, tabelas estatísticas, etc.. Ao combinar vários tipos de dados também se combinam as incertezas associadas às várias fontes de dados (Ehlers e Wenzhong, 1996). Refira-se que a incerteza associada aos dados pode incluir incerteza posicional, temática, lógica ou temporal.

Relativamente à visualização da qualidade dos dados espaciais, MacEacheren *et al.* (1993; 1994) descrevem três diferentes tipos de métodos para apresentar a incerteza: um par de mapas lado a lado, mapas bivariáveis e apresentação sequencial (incluindo animação interactiva). Num par de mapas lado a lado, a imagem de dados e a imagem da confiança são visualizadas à mesma escala na mesma gama de valores de saturação diferindo apenas a sua tonalidade, o que permite a sua comparação. Nos mapas bivariáveis, a visualização dos dados e da sua confiança é conjunta o que requer a sobreposição de variáveis visuais contrastantes. A estratégia adoptada por MacEacheren *et al.* (1993) consistiu em combinar o uso de símbolos pontuais, para representar a confiança, com a cor, para representar os dados. No terceiro método, as imagens dos dados e da confiança são mostradas alternadamente segundo um determinado intervalo de tempo. MacEacheren *et al.* (1993) desenvolveram uma ferramenta de visualização da confiança (RVIS) que suportava várias opções, entre elas as acima referidas, para visualização dos dados e metadados. A confiança era estimada, neste sistema, com base na *krigagem* e validação cruzada.

Ficher (1993; 1994) desenvolveu uma técnica referida como animação de erros para

visualizar a confiança da classificação de imagens e mapas de solos. No caso da classificação de imagens, a incerteza inerente à atribuição de um *pixel* a uma classe era transmitida fazendo a cor de um *pixel* proporcional ao valor da sua pertença a uma determinada classe.

Faiz e Boursier (1994) propôs uma abordagem orientada por objectos para modelar e disponibilizar a qualidade dos dados espaciais. A abordagem considera a construção de uma qualidade por níveis em que a qualidade relacionada com metadados pode ser associada aos objectos geográficos de diferentes níveis.

Paradis e Beard (1994) desenvolveram um filtro que permitia ao utilizador especificar parâmetros de qualidade dos dados (e.g., precisão posicional), medição da qualidade (e.g., erro médio quadrático (RMSE - *root mean square error*)) e um valor limiar que era aplicado aos dados podendo ser visualizados apenas aqueles que satisfaziam ou não o referido limiar. Os utilizadores eram informados da quantidade de dados que não cumpriam o limiar.

Hunter e Goodchild (1995) descreveram uma abordagem baseada num mapa de probabilidades para representar a incerteza da posição horizontal de um possível valor de elevação do terreno. Era calculada a probabilidade de uma célula exceder ou ser excedida por um determinado valor limiar. Após o cálculo, a visualização podia ser efectuada utilizando uma gradação de cores.

Mitasova *et al.* (1995) desenvolveram uma ferramenta de visualização que incorporava interpolação multidimensional, visualização do modelo resultante, previsão da precisão dos resultados do modelo usando validação cruzada. A ferramenta de visualização foi incorporada no *software* GRASS GIS.

Ehlers e Wenzhong (1996) desenvolveram um método designado por *S-Model* para combinar a incerteza posicional e temática resultante da integração de dados de detecção remota e dados SIG (figura 2.3). Relativamente à incerteza temática, o modelo desenvolvido considera apenas a resultante da classificação de imagens de satélite utilizando o método da máxima verosimilhança. A análise da incerteza da classificação é efectuada utilizando o valor da máxima probabilidade da verosimilhança de cada *pixel*, retido no resultado da classificação. Com base nesse valor é calculada a distribuição da frequência de probabilidade conforme ilustra o quadro 2.1. Utilizando este tipo de descrição o utilizador sabe a distribuição espacial para cada classe e a certeza ou incerteza da classificação.

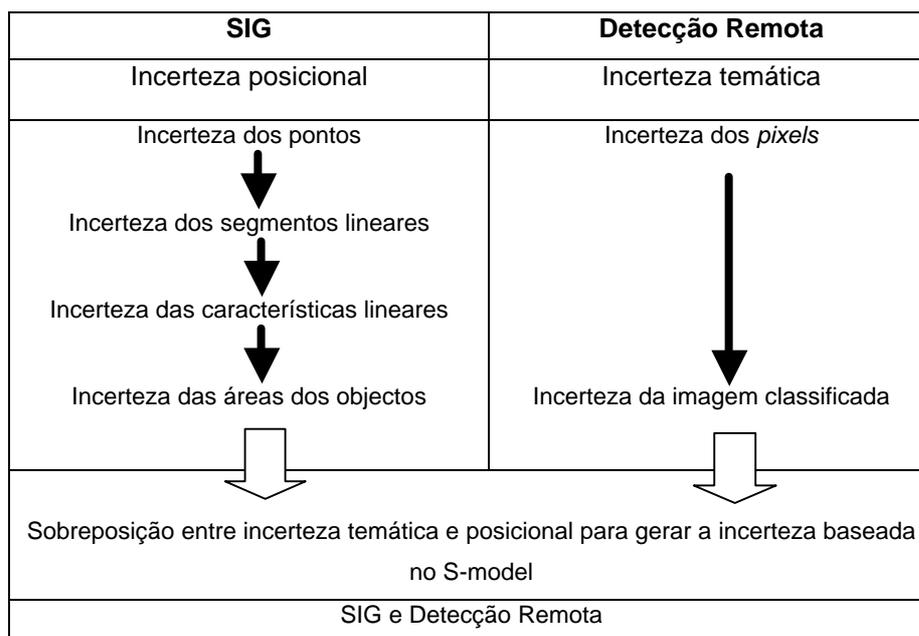


Figura 2.3 - Modelação da incerteza posicional e temática dos objectos usando o *S-model* (adaptado de Ehlers e Wenzhong (1996)).

Quadro 2.1 - Distribuição da frequência dos valores da máxima probabilidade. Adaptado de Ehlers e Wenzhong (1996).

Probabilidades	0-10	>10-20	>20-30	>30-40	>40-50	>50-60	>60-70	>70-80	>80-90	>90-100	Soma
Nº de <i>pixels</i> por classe											

Apesar dos esforços e das investigações efectuadas nesta última década, o acesso à qualidade dos dados através da visualização, ou de outros meios, não se encontra ainda disponível nos *softwares* de SIG existentes no mercado ou ainda não está suficientemente desenvolvida. Na área do processamento e análise de imagem foi recentemente desenvolvido um *software*, eCognition, no qual se encontra implementado o método de análise orientado por objectos, em que é possível aceder à visualização gráfica da incerteza temática. Esta informação é importante pois permite avaliar a estabilidade da classificação efectuada, auxiliando o próprio processo de classificação. Uma das limitações do *software* é não ser flexível, não permitindo qualquer manipulação da informação como, por exemplo, visualizar apenas os dados que satisfaçam um determinado valor de incerteza ou visualizar a informação por classes. Por outro lado, não possibilita a exportação da incerteza da classificação para que o utilizador dos dados possa aceder a essa informação noutros ambientes (e.g., SIG).

CAPÍTULO 3 - Metodologia proposta para produção de cartografia temática de ocupação do solo

Neste capítulo apresenta-se a metodologia desenvolvida neste estudo, baseada na análise de imagens orientada por objectos, para a produção de cartografia de ocupação do solo, com base em imagens de grande resolução espacial.

A análise de imagens orientada por objectos é uma abordagem relativamente recente e, até ao momento, existem poucas aplicações operacionais. A terminologia “orientação por objectos” está ligada ao próprio método de análise de imagem. No trabalho a realizar pretende-se utilizar o *software* eCognition como ferramenta para desenvolvimento da metodologia a aplicar. Esta opção prende-se com o facto de, na data em que começou a ser realizado este trabalho (Janeiro de 2001), ser o único *software* comercial no qual estava implementado o método de análise orientado por objectos e que permitia, na fase da classificação, serem utilizados para além dos dados espectrais, os da forma, textura, relações de vizinhança, hierarquia e contexto.

As razões para a escolha da análise de imagens orientada por objectos são várias: o processamento de imagens aproxima-se mais dos processos cognitivos humanos do que as análises baseadas no *pixel* (Baatz e Schape, 2000); os utilizadores dos SIG estão a utilizar cada vez mais a forma vectorial para lidar com a geoinformação e é esperado que as formas resultantes da análise de dados de observações terrestres forneçam uma representação apropriada das estruturas do mundo real; é mais fácil incorporar informação de contexto com significado numa abordagem orientada por objectos do que numa abordagem ao nível do *pixel*. A área verde urbana, por exemplo, só pode ser classificada como tal e distinguida de outras áreas com uma assinatura espectral semelhante se se puder utilizar o meio que a envolve. Se a única informação for a assinatura espectral ao nível do *pixel*, este tipo de classificação não é possível e não se poderia distinguir áreas verdes urbanas de vegetação natural ou floresta.

A extracção dos objectos é efectuada utilizando o método de segmentação multi-resolução (Baatz e Schape, 2000). Com a extracção dos objectos imagem resulta também um vasto conjunto de informação adicional, para além da mera informação espectral, nomeadamente forma, tamanho, textura, hierarquia, informação baseada nas relações entre os objectos, permitindo que no processo de classificação as regras de decisão se baseiem não apenas nos dados espectrais mas também nas relações espaciais de um dado objecto com os objectos vizinhos.

As imagens de detecção remota são uma fonte de dados importante para aplicações

SIG e, inversamente, as capacidades dos SIG podem ser utilizadas para melhorar o processo de análise da imagem. No presente trabalho, a detecção remota será utilizada como ferramenta para adquirir a informação de ocupação/uso do solo não existente relativamente à área a estudar.

A metodologia a aplicar é composta pelas seguintes fases: (1) definição da nomenclatura; (2) compilação e tratamento da informação auxiliar existente; (3) pré-processamento das imagens; (4) segmentação da imagem para criação dos objectos imagem; (5) desenvolvimento de bases de conhecimento estruturadas sob a forma de uma hierarquia de classes para obtenção da informação temática; (6) avaliação da qualidade dos mapas produzidos através da construção de uma matriz de erro e análise da incerteza temática; (7) integração dos mapas produzidos num SIG vectorial e interpretação do mapa em ambiente SIG; (8) cartografia da incerteza temática.

3.1 Definição da nomenclatura

Quando se pretende elaborar um mapa temático de ocupação do solo devem ser escolhidas e definidas as classes de interesse para classificar os dados de detecção remota em informação de ocupação/uso do solo (Gong e Howarth, 1992). Para tal é estabelecido um esquema de classificação, também designado por nomenclatura de referência, que contém as definições taxonómicas das classes de informação, as quais estão organizadas de acordo com determinado critério. Com base no esquema de classificação estabelecido é organizada e categorizada a informação que pode ser extraída dos dados (Jensen, 1996).

Quando se pretende aplicar um esquema de classificação é necessário ter em conta a resolução espectral e a resolução espacial dos dados imagem utilizados para a produção de cartografia. O nível de detalhe exigido num esquema de classificação está relacionado com a resolução espacial das imagens às quais se pretende aplicar.

Neste estudo, o esquema de classificação será estabelecido com base: (1) na nomenclatura CORINE Land Cover e CLUSTERS (*Classification for Land Use Statistics: Eurostats Remote Sensing Programme*); (2) conhecimento do analista sobre a área de estudo; (3) levantamento da informação auxiliar existente.

A análise das classes de informação que existem na área de estudo, com base no conhecimento do analista, é uma etapa muito importante pois reduz o universo da análise (Navarro, 1999). Por outro lado, a recolha de informação existente na área de estudo permitirá enriquecer a nomenclatura de base.

3.2 Pré - Processamento da imagem

O pré-processamento das imagens inclui a correcção geométrica da imagem pancromática e das imagens multiespectrais, para que estas fiquem geo-referenciadas relativamente ao sistema de projecção cartográfico da cartografia de base utilizada. A correcção geométrica é efectuada utilizando pontos de controle. Para efectuar a transformação matemática, que permitirá recolocar cada *pixel* das imagens originais com coordenadas (x,y) na posição correspondente nas imagens rectificadas com coordenadas (M,P), recorrer-se-á a um polinómio de 1ª ordem também designado por Transformação Afim. A aplicação deste polinómio tem a vantagem de originar menos distorções em zonas da imagem em que não são definidos pontos de controle. No processo de reamostragem é usado o algoritmo do vizinho mais próximo, pois é o único que mantém os valores espectrais originais.

Ao contrário das distorções geométricas, em que as fontes são corrigidas conjuntamente, os procedimentos de correcção radiométrica, necessários num determinado estudo, dependem das várias fontes de distorção presentes na imagem, nomeadamente, topografia, uniformidade da atmosfera na área em estudo, condições de iluminação, ângulo de observação e do tipo de estudo (unitemporal ou multitemporal).

Dado que se pretende produzir um mapa de ocupação do solo para uma só data, as correcções radiométricas a efectuar serão decididas em função das características topográficas e da uniformidade da atmosfera na área em estudo.

3.3 Extracção da informação temática com base na análise de imagem orientada por objectos

Para a obtenção da informação temática, o método utilizado baseia-se na análise de imagens orientada por objectos. A fase de extracção da informação temática envolve três etapas distintas: (1) segmentação da imagem para criação dos objectos imagem; (2) construção da base de conhecimento estruturada sob a forma de uma hierarquia de classes para classificação dos objectos anteriormente criados; (3) classificação dos objectos imagem. Na figura 3.1 apresenta-se, esquematicamente, a metodologia proposta para a extracção da informação temática. Nas secções seguintes é feito o desenvolvimento de cada uma das etapas do método proposto.

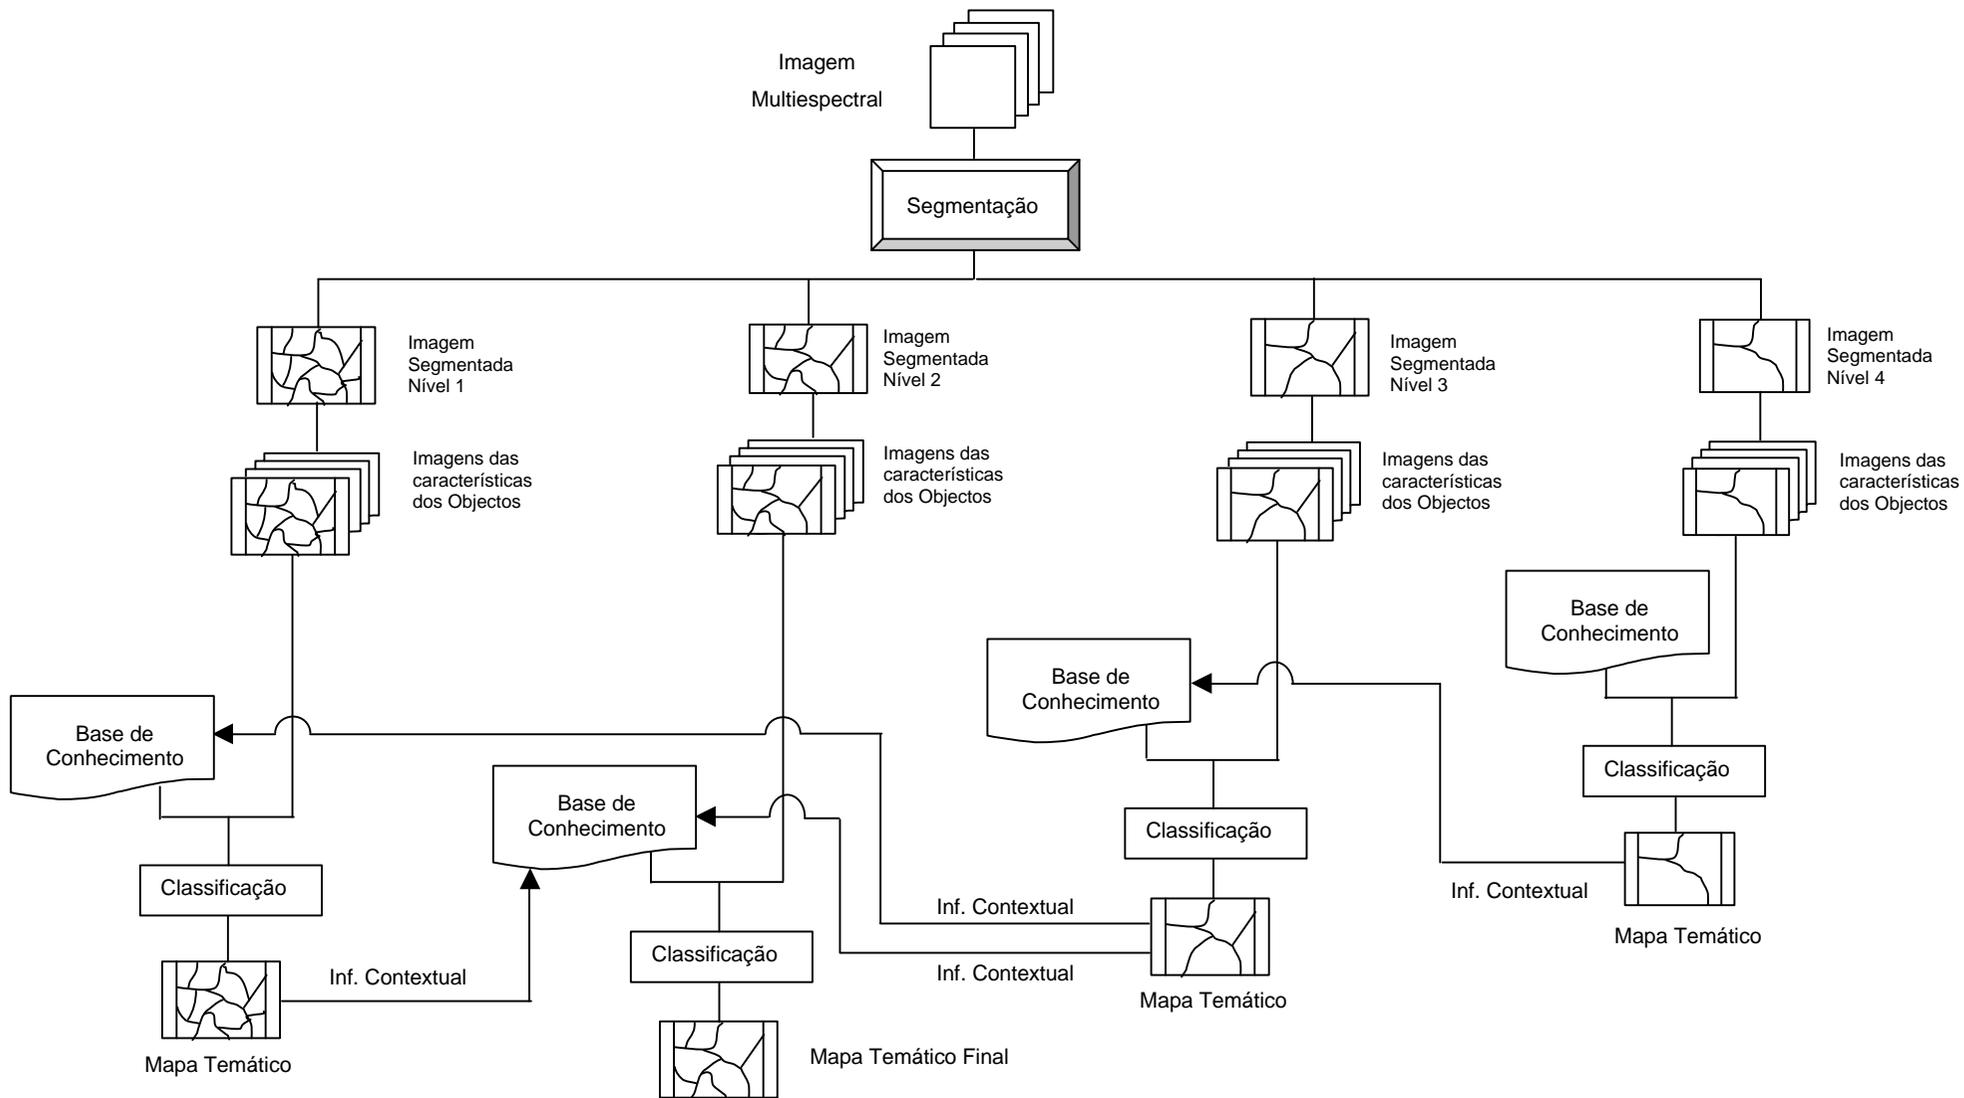


Figura 3.1 - Esquema da metodologia proposta

3.3.1 Segmentação da imagem

Para efectuar a análise de imagem, utilizando uma abordagem orientada por objectos, é necessário proceder primeiro à sua segmentação. O método usado no estudo para segmentar a imagem foi desenvolvido recentemente, sendo designado por segmentação multi-resolução (Batz e Schape, 2000). Esta nova técnica permite a extracção de objectos homogéneos da imagem, em qualquer resolução que se pretenda, tendo especialmente em conta contrastes locais.

A segmentação multi-resolução consiste na fusão de regiões começando por um *pixel* objecto. Em passos seguintes, pequenos objectos imagem são agregados originando outros maiores podendo ser registados em níveis diferentes. Estes tornar-se-ão sub ou super-objectos de um nível existente, pois cada objecto é gerado com base no que conhece dos seus objectos vizinhos em termos verticais e horizontais. Isto permite criar uma rede hierárquica dos objectos imagem com uma topologia definida. O limite de um super-objecto (objecto maior) é consistente com os limites dos seus sub-objectos (objecto menor), conforme ilustra a figura 3.2. Desta forma, estruturas de diferentes escalas podem ser representadas simultaneamente e assim classificadas umas em relação às outras.

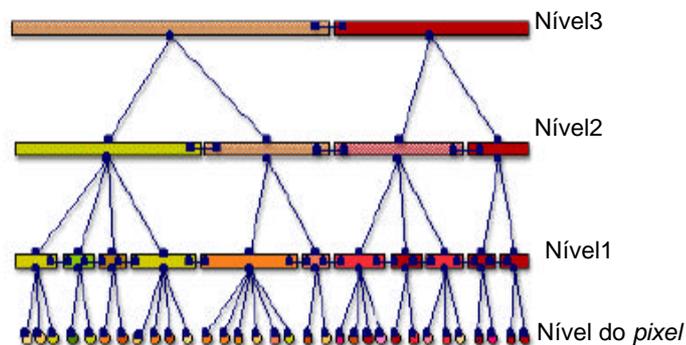


Figura 3.2 - Rede hierárquica de objectos imagem (adaptado de Batz *et al.* (2000)).

Neste processo (*clustering*) está subjacente um procedimento de optimização que minimiza a heterogeneidade $n.h$ dos objectos imagem resultantes, em que n é o tamanho de um objecto e h uma definição arbitrária de heterogeneidade.

A determinação da heterogeneidade espectral é obtida através da soma do produto do desvio padrão s_c dos valores espectrais de cada banda com os pesos w_c atribuídos pelo utilizador a cada banda conforme se apresenta:

$$(1) h_{\text{espectral}} = \sum_c w_c s_c$$

Em muitos casos a segmentação baseada apenas na minimização da heterogeneidade espectral pode originar segmentos muito ramificados conforme ilustra a figura 3.3. Este efeito é ainda mais forte em dados altamente texturados como são os dados radar (Baatz *et al.*, 2000).

Por esta razão, é útil juntar ao critério da heterogeneidade espectral o critério de heterogeneidade da forma, com o sentido de reduzir o desvio da compacidade e suavização da forma. Esta é determinada pelo quociente entre o perímetro do objecto imagem l e a raiz quadrada do número n de *pixels* que formam o objecto imagem conforme se apresenta:

$$(2) h_{comp} = \frac{l}{\sqrt{n}}$$

Outra possibilidade de descrever a heterogeneidade da forma é através do quociente entre o perímetro do objecto imagem l e o perímetro mínimo obtido por uma caixa envolvente ao objecto imagem paralela aos *pixels* que constituem o objecto b como se segue:

$$(3) h_{suave} = \frac{l}{b}$$

Para aplicar o algoritmo de segmentação é necessário definir o peso que se atribui a cada uma das bandas, a escala e o peso que se atribui à cor e à forma. Deve-se ainda definir o peso que se atribui à compacidade dos objectos e o nível em que se quer guardar a segmentação. Estes parâmetros são definidos pelo utilizador:

Peso das bandas da imagem – o utilizador pode definir quais as bandas que devem ter mais peso no processo de segmentação da imagem. No caso dos dados imagem, cujas bandas são comparáveis em tamanho e conteúdo, os pesos devem ser iguais.

Parâmetro de escala - o parâmetro escala determina a máxima heterogeneidade espectral que pode ocorrer entre dois objectos para que possam ser agregados, influenciando o tamanho médio dos objectos gerados.

Cor / forma - está relacionado com a influência da homogeneidade cor vs. a forma. Quanto mais elevado o critério da forma, menor é a influência da homogeneidade espectral na geração dos objectos. O valor a atribuir a este parâmetro pode variar no intervalo [0,1].

Suavização / compacidade – este critério permite reduzir o desvio da compacidade e suavização da forma evitando que se gerem objectos muito ramificados conforme ilustra a figura 3.3. Quando o critério forma é superior a zero, o utilizador pode determinar se os objectos deverão ser ou mais compactos ou mais suavizados. O valor a atribuir a este parâmetro pode variar no intervalo [0,1].

Nível – determina se o novo nível gerado da imagem será rescrito sobre o corrente nível ou se, por outro lado, os objectos gerados tornar-se-ão sub ou super-objectos de um

nível existente. Isto possibilita a representação simultânea da informação da imagem em diferentes escalas e a construção de uma hierarquia de objectos.

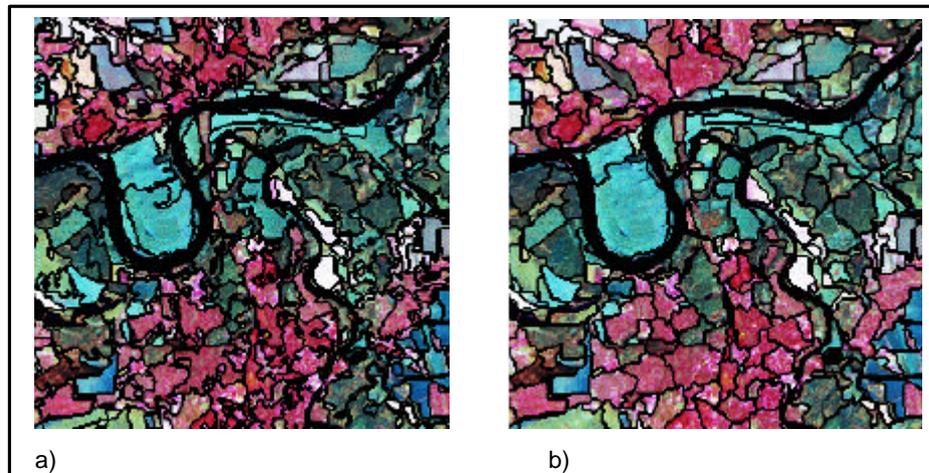


Figura 3.3 - A imagem a) ilustra a segmentação de uma imagem Landsat com optimização exclusiva da heterogeneidade espectral. A imagem b) ilustra a segmentação com optimização da heterogeneidade espectral e da forma. Adaptado de Baatz *et al.* (2000).

Como referido, o parâmetro escala definido pelo utilizador determina a máxima heterogeneidade espectral que pode ocorrer entre dois objectos para que possam ser agregados. A partir do valor do parâmetro escala, é determinada a sua raiz quadrada que irá servir como limiar para avaliar uma possível fusão de dois objectos imagem contíguos. Para tal é calculado o valor de heterogeneidade entre eles e comparado com a raiz quadrada do parâmetro escala.

O valor de heterogeneidade, também designado por valor de fusão f , é apurado com base na heterogeneidade espectral h_{cor} e na heterogeneidade da forma h_{forma} de dois objectos pela seguinte expressão:

$$(4) f = w \cdot h_{cor} + (1 - w) \cdot h_{forma}$$

em que w é o peso do parâmetro cor atribuído pelo utilizador e que pode tomar valores compreendidos no intervalo [0,1].

A heterogeneidade da cor é avaliada calculando a diferença entre a situação depois e antes da fusão dos referidos objectos através da seguinte expressão:

$$(5) h_{cor} = \sum_c w_c (n_{fusão} \cdot s_c^{fusão} - (n_{obj1} \cdot s_c^{Obj1} + n_{obj2} \cdot s_c^{Obj2}))$$

O desvio padrão s_c é ponderado através do tamanho dos objectos n_{obj} para cada banda c .

O critério de heterogeneidade da forma h_{forma} é calculado com base na compacidade

h_{comp} e na suavização h_{suave} pela expressão:

$$(6) h_{\text{forma}} = w_{\text{comp}} \cdot h_{\text{comp}} + (1 - w_{\text{comp}}) \cdot h_{\text{suave}}$$

em que w_{comp} é o peso do parâmetro compacidade atribuído pelo utilizador e que pode tomar valores compreendidos entre [0,1].

Também neste caso, a heterogeneidade da forma causada pela fusão é avaliada calculando a diferença entre a situação depois e antes da fusão relativamente à compacidade e suavização:

$$(7) h_{\text{suave}} = n_{\text{fusão}} \cdot \frac{l_{\text{fusão}}}{b_{\text{fusão}}} - \left(n_{\text{Obj1}} \cdot \frac{l_{\text{Obj1}}}{b_{\text{Obj1}}} + n_{\text{Obj2}} \cdot \frac{l_{\text{Obj2}}}{b_{\text{Obj2}}} \right)$$

$$(8) h_{\text{comp}} = n_{\text{fusão}} \cdot \frac{l_{\text{fusão}}}{\sqrt{n_{\text{fusão}}}} - \left(n_{\text{Obj1}} \cdot \frac{l_{\text{Obj1}}}{\sqrt{n_{\text{Obj1}}}} + n_{\text{Obj2}} \cdot \frac{l_{\text{Obj2}}}{\sqrt{n_{\text{Obj2}}}} \right)$$

sendo n o tamanho do objecto, l o perímetro do objecto e b o perímetro da caixa envolvente.

Como os segmentos da imagem gerados são a base para uma classificação posterior, será importante uma apropriada segmentação da imagem, devendo-se gerar, o mais possível, objectos com ‘significado’, ou seja, a forma de cada objecto deverá idealmente ser representada por um objecto imagem, tendo em conta os objectivos a atingir na classificação. O tamanho médio dos objectos imagem deve estar de acordo com a escala de interesse.

Este método permite construir uma rede hierárquica de objectos imagem que representam simultaneamente a informação da imagem em diferentes resoluções espaciais. No estudo pretende-se criar uma rede hierárquica de objectos imagem para que cada objecto, na fase de classificação, “conheça” o seu contexto (vizinhança), os seus super-objectos e os seus sub-objectos. Deste modo, será possível definir relações entre eles como, por exemplo, “80% dos limites relacionados com *Áreas residenciais contínuas*” e utilizar este tipo de informação de contexto local para classificar *Espaços verdes urbanos*. Outras possibilidades serão: permitir efectuar a análise de objectos baseada nos seus sub-objectos, como sejam análises de textura; classificar um objecto imagem com base nos atributos de todos os sub-objectos que pode ser, por exemplo, a forma; efectuar análises lineares baseadas nos sub-objectos e relacionar características de classes (e.g., classificar objectos como *Áreas residênciais contínuas* com base na análise da área dos sub-objectos classificados como *Habituação*).

3.3.2 Características dos objectos imagem

Os objectos imagem, resultantes da segmentação, funcionam como objectos primários aos quais pode ser associada uma vasta informação, para posterior utilização na sua classificação. A partir das imagens numéricas multiespectrais representadas de forma matricial, constituídas por N linhas e M colunas, em que os *pixels* continham um único valor nas diferentes bandas (medida da energia electromagnética proveniente da superfície que é detectada pelo sensor e transformada em sinal numérico), são extraídas novas imagens constituídas por objectos que possuem uma forma poligonal. A cada objecto está associado um conjunto de atributos, nomeadamente: (1) informação espectral, obtida com base nos valores espectrais dos *pixels* (média, desvio padrão, vizinhança, quocientes); (2) informação da forma do próprio objecto gerado ou dos seus sub-objectos (e.g., área, direcção principal, assimetria, comprimento); (3) textura baseada na análise dos sub-objectos; (4) informação sobre a hierarquia (quadro 3.1). Na figura 3.4 são apresentados, como exemplo, três tipos de informação associada aos objectos imagens obtidos com o método de segmentação multi-resolução e uma correspondente ampliação em que é visível o valor dos diferentes atributos associados a um objecto seleccionado.

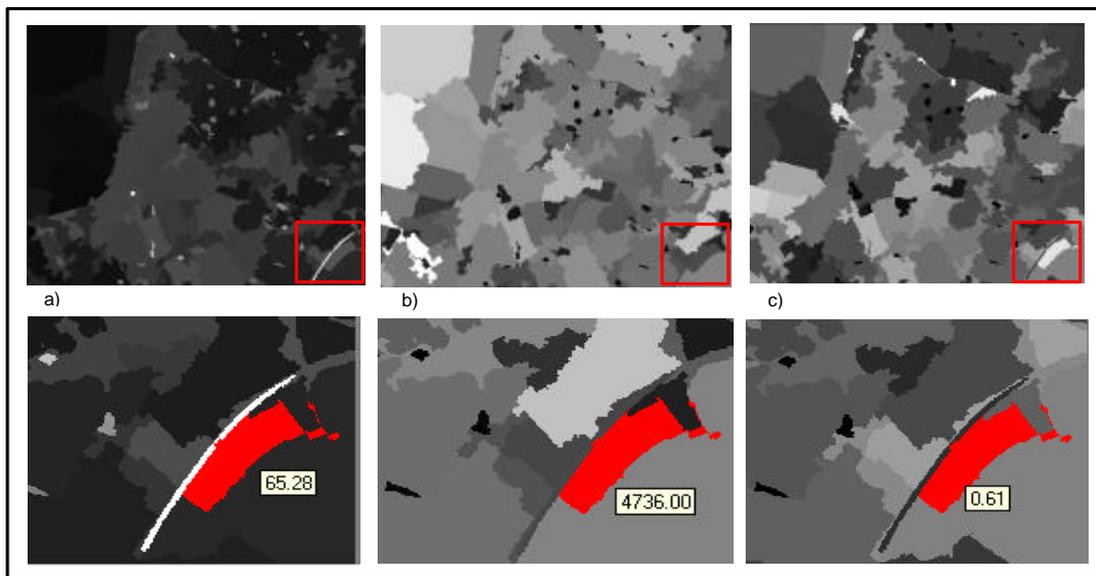
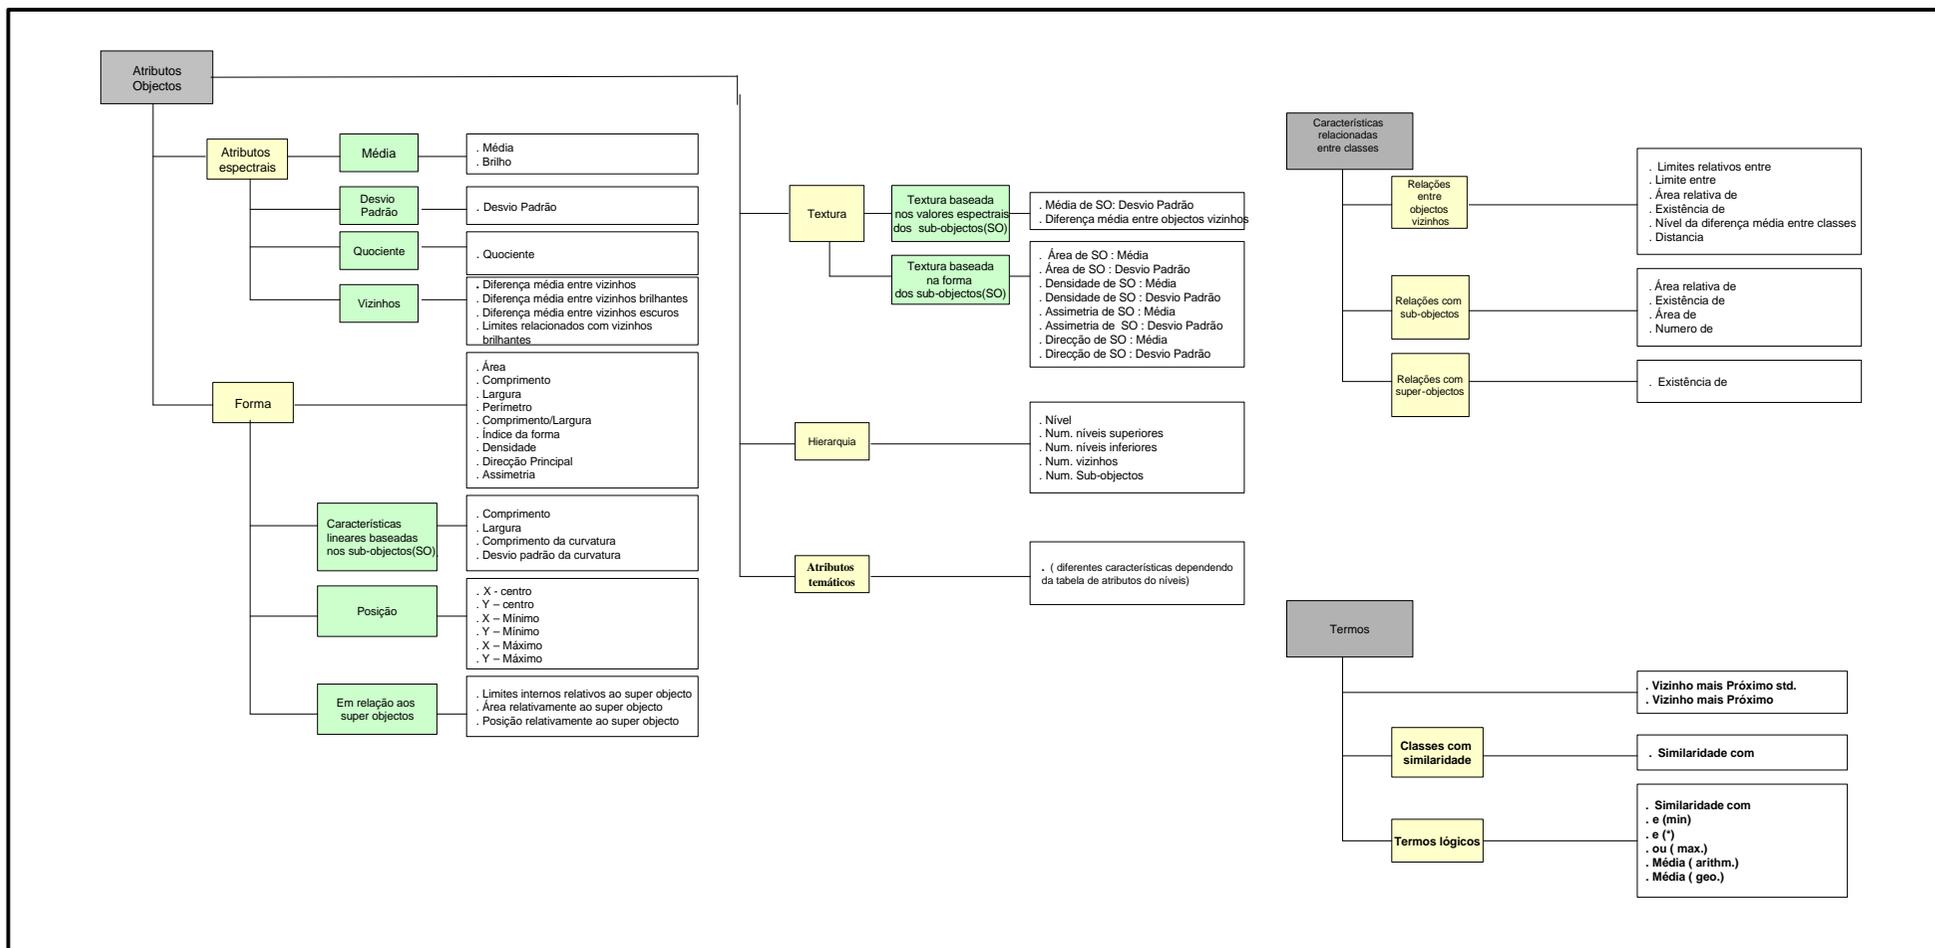


Figura 3.4 - Exemplo de atributos associados aos objectos obtidos com a segmentação multi-resolução. Fig.3.4 a) média dos valores espectrais dos *pixels* que constituem os objectos na banda do infravermelho próximo. Fig. 3.4 b) perímetro dos objectos; Fig. 3.4 c) textura obtida a partir do desvio padrão dos seus sub-objectos. Nas imagens inferiores seleccionou-se um objecto e apresenta-se o seu valor na característica em causa.

Quadro 3.1 - Atributos dos objectos obtidos com a segmentação multi-resolução.



3.3.3 Desenvolvimento de bases de conhecimento

A classificação dos objectos imagem gerados, na fase de segmentação, é feita a partir de uma base de conhecimento estruturada sob a forma de uma hierarquia de classes. As classes são constituídas por um conjunto de critérios relativos aos atributos dos objectos imagem criados. A construção da hierarquia de classes consiste, assim, em gerar uma base de conhecimento em que, em cada classe, são 'descritas', através de funções, as propriedades dos objectos que devem pertencer a essa classe. As relações definidas na hierarquia de classes serão de dois tipos: herança e grupos semânticos. As relações de herança permitem que a descrição das classes paternas seja transmitida às suas classes filhas. Cada classe pode herdar propriedades de uma ou mais classes paternas e transmiti-las para as suas classes filhas. Deste modo reduz-se a redundância e complexidade na descrição das classes.

Os grupos semânticos permitem combinar várias classes separadas pela classificação numa classe superior com significado semântico. Por exemplo, as classes *Áreas residenciais contínuas*, *Espaços verdes urbanos* podem ser classes filhas de classes paternas diferentes, *Artificial* e *Floresta*, respectivamente, tendo herdado parte das suas propriedades das respectivas classes paternas. Contudo, nas relações de grupo hierárquicas elas podem ser classes filhas da classe paterna *Urbano*, fazendo as classes *Áreas residenciais contínuas*, *Espaços verdes urbanos* parte de uma classe superior com significado semântico.

Cada tipo de informação de ocupação do solo será extraída com a técnica mais adequada às suas características, podendo ser usadas de forma combinada.

As técnicas utilizadas na classificação serão baseadas em funções de pertença *fuzzy*, classificador do vizinho mais próximo, informação contextual e técnica de máscaras. Seguidamente será efectuado um breve desenvolvimento de cada uma das técnicas a aplicar.

Funções de pertença

As funções de pertença permitem a formulação de conhecimento e conceitos. Estas funções constituem um método que permite transformar uma gama de valores arbitrários num intervalo uniforme de valores entre 0 e 1. Cada valor obtido no intervalo [0,1] é o resultado da transformação efectuada pela função de pertença após a avaliação dos valores dos objectos imagem relativos a cada um dos atributos ou características que formam a

descrição da classe.

Dependendo da forma da função de pertença, a transição entre “sim” e “não” pode ser rígida ou *fuzzy*. Na figura 3.5 são exemplificadas duas função de pertença, uma do tipo rectangular que define o conjunto rígido M e outra do tipo trapezoidal que define o conjunto fuzzy A , ambas no espaço característico c , onde $ymin$ é o menor valor para a função, $ymax$ o maior valor, i o início do trapézio, m_1 e m_2 o início e fim do intervalo no qual a função assume o valor máximo e f o fim do trapézio. No caso da função de pertença ser do tipo rectangular, os valores da variável c compreendidos entre $[i, m_1[$ e $]m_2, f]$ serão transformados no valor 0 e os valores no intervalo $[m_1, m_2]$ serão transformados no valor 1 (conjunto M). No caso da função trapezoidal, os valores da variável c compreendidos entre $[i, m_1[$ e $]m_2, f]$ serão transformados pela função em valores no intervalo $[0, 1[$ (conjunto A) e os valores no intervalo $[m_1, m_2]$ serão também transformados no valor 1.

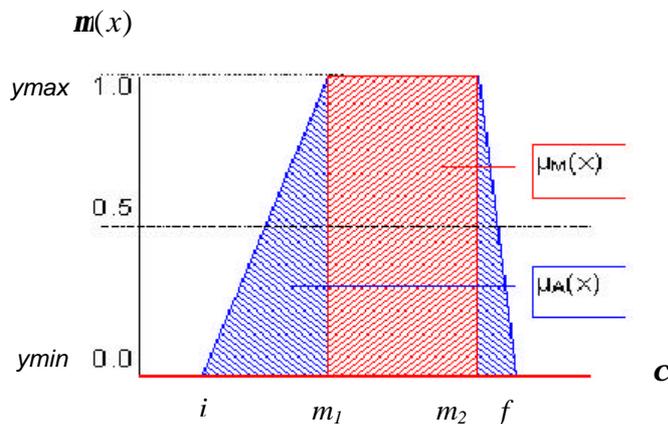


Figura 3.5 - Exemplo de uma função de pertença rectangular e trapezoidal relativa ao atributo x para definir um conjunto M rígido (crisp), representado a vermelho, e um conjunto A *fuzzy* representado a azul. Adaptado de Baatz *et al.* (2000).

É possível definir mais do que um conjunto *fuzzy* para um espaço característico. Por exemplo, podem-se definir os conjuntos *fuzzy* urbano, agricultura e floresta para um mesmo espaço característico de objectos. Contudo, quantas mais sobreposições ocorrerem entre os conjuntos *fuzzy* mais ambígua será a classificação final.

Como exemplo, na figura 3.6, são definidos três conjuntos *fuzzy* urbano, agricultura, e floresta no espaço característico c que assume valores no intervalo $[0, 255]$. Os conjuntos urbano e agricultura são definidos por funções de pertença triangulares, e o conjunto floresta por uma função de pertença trapezoidal.

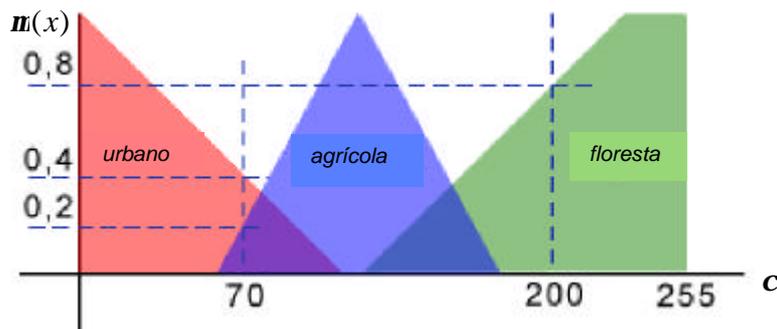


Figura 3.6 - Exemplo de três conjuntos *fuzzy*: urbano, agricultura e floresta definidos no espaço característico C , cuja variação de valores é apresentada no eixo do x , e caracterizados pela sobreposição de funções de pertinência triangular e trapezoidal. No eixo dos y são apresentados os valores resultantes da transformação efectuada pelas funções de pertinência e que representam o grau de pertinência às classes. Adaptado de Baatz *et al.* (2000).

Para um objecto imagem com um valor de $x=70$, no espaço característico c considerado, a pertinência à classe *Urbano* é 0.4, à classe *Agricultura* é 0.2 e à classe *Floresta* é 0.0. Se o valor do objecto imagem for igual a 200, a pertinência às classes é de 0.0, 0.0, e 0.8 respectivamente. Os objectos cujos valores característicos estão contidos na gama de valores sobrepostos podem ser encarados como objectos ambíguos, uma vez que respeitam o critério de mais do que uma classe.

Para uma classificação bem sucedida, a escolha das funções de pertinência é crucial. Quanto melhor for modelado o conhecimento sobre o caso em estudo pelas funções de pertinência, melhor é o resultado da classificação.

Utilizando operadores lógicos, podem-se conjugar várias funções de pertinência para melhor discriminar os objectos que pertencem a uma determinada classe, conforme ilustra a figura 3.7.

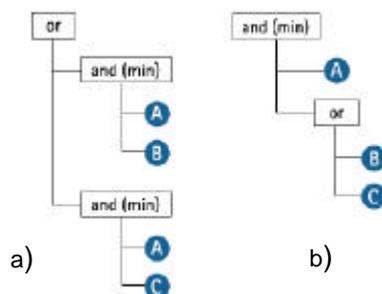


Figura 3.7 - Os exemplos a) e b) ilustram como as funções de pertinência podem ser combinadas, através de operadores lógicos, para constituir uma descrição da classe. No exemplo a) a expressão A e B ou a expressão A e C têm que ser cumpridas pelos atributos dos objectos imagem, para que estes sejam classificados. No exemplo b) a expressão A e a expressão B ou C têm que ser cumpridas pelos atributos dos objectos imagem, para que estes sejam classificados.

Classificador do vizinho mais próximo

O classificador assistido do vizinho mais próximo classifica os objectos imagem num dado espaço característico com base em áreas de treino representativas das classes em causa. Depois de definido um conjunto representativo de amostras de objectos para cada classe e os espaços característicos, a classificação de um objecto imagem x consiste em fazer uma busca exaustiva para todos os objectos amostra com vista a determinar aquele que se encontra mais perto no espaço característico. A classe desse objecto amostra é a classe em que x é classificado. A figura 3.8 ilustra a utilização do método do vizinho mais próximo na classificação de um objecto imagem x nos espaços característicos x_1 e x_2 .

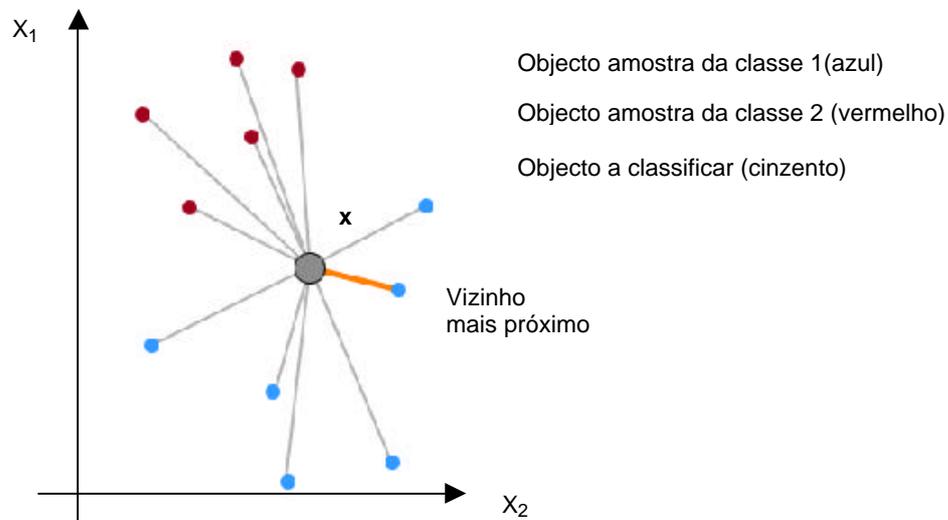


Figura 3.8 - Método do vizinho mais próximo.

Para efectuar a medição entre o objecto amostra e os objectos imagem num espaço característico é adoptada a seguinte métrica:

$$(9) \quad d = \sqrt{\sum_f \left[\frac{v_f^{(s)} - v_f^{(o)}}{\sigma_f} \right]^2}$$

d - Distância entre o objecto amostra S e o objecto imagem O

$v_f^{(s)}$ - Valor do objecto amostra para o atributo f

$v_f^{(o)}$ - Valor do objecto imagem para o atributo f

σ_f - Desvio Padrão dos objectos imagem para o atributo f

A atribuição dos objectos a todas as classes é efectuada pela atribuição de valores no intervalo de '0' (nenhuma atribuição) a '1' (total atribuição). Isto é, um objecto imagem que esteja localizado perto de uma amostra da classe X tem de ser atribuído a essa classe com um valor de pertença entre 0 e 1. Com base na distância d e numa função denominada função declive, é calculado a partir de uma função de pertença exponencial (10) o grau de pertença com que cada objecto é atribuído à classe. A função de pertença é definida pela seguinte expressão:

$$(10) Z(d) = e^{-k \cdot d^2} \text{ em que } (11) K = \ln(1/\text{função declive})$$

O valor da função declive pode variar de 0 a 1 e é um valor atribuído pelo utilizador. O parâmetro K determina o decréscimo de $Z(d)$. Quando o valor da distância é 1, o valor da função $z(d)$ é igual à função declive (figura 3.9). Esta situação ocorre se, num espaço característico, a distância entre o objecto amostra dessa classe e o objecto imagem mais próximo é igual ao desvio padrão dos objectos imagem nesse espaço. A figura 3.9 exemplifica a variação dos valores para a função de pertença $Z(d)$ em função dos diferentes valores obtidos para a distância entre o objecto imagem a classificar e o objecto amostra, considerando que a função declive definida pelo utilizador é 0.2.

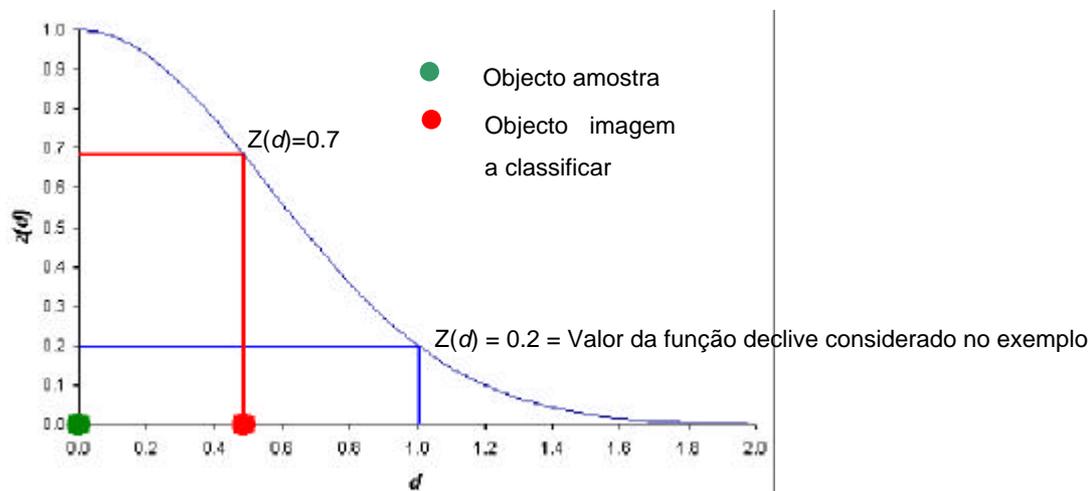


Figura 3.9 - Exemplo da função de pertença do vizinho mais próximo. O cálculo da função de pertença depende do valor da função declive e inicia-se a partir do objecto amostra (ponto verde). Para um valor da distância, entre o objecto amostra e o objecto a classificar, de 0.5 resulta um valor de pertença 0.7 à classe à qual o objecto amostra pertence. Se a distância fosse 1, o valor da função $z(d)$ seria igual à função declive resultando um valor de pertença de 0.2.

Quanto mais próximo um objecto imagem estiver de um objecto amostra representativo de uma classe, maior será o grau de pertença a essa classe, mas como

referido acima, o seu resultado depende também do valor atribuído à função declive.

A figura 3.10 ilustra as alterações da função exponencial $Z(d)$ para diferentes valores da função declive.

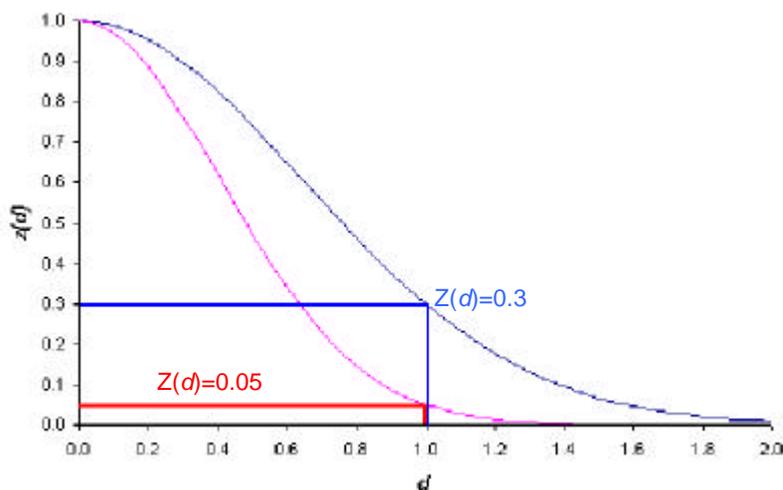


Figura 3.10 - Classificação do vizinho mais próximo. Para o mesmo valor da distância entre objecto amostra e o objecto a classificar obtêm-se diferentes valores de pertença para diferentes valores da função declive. Os valores da função declive são de 0.3 e 0.05 para o cálculo da função azul e lilás, respectivamente.

Quanto mais pequeno o valor da função declive, mais ‘perto’ os objectos têm de estar do objecto amostra no espaço característico para serem classificados. Se o valor de pertença obtido pela função de pertença $Z(d)$ for inferior ao valor de pertença mínimo então o objecto não é classificado (no *software* eCognition, no qual o algoritmo está implementado, o valor mínimo é 0.1).

Diferenciação de classes usando informação contextual

Este método consiste em utilizar a classificação de determinados objectos imagem como contexto para a classificação de outros objectos imagem pertencentes à rede hierárquica. É usada a relação espacial entre objectos imagem adjacentes (em termos horizontais e verticais) para classificar um determinado objecto. Por exemplo, para efectuar a classificação dos *Espaços verdes urbanos* será necessário efectuar primeiro a classificação das classes *Floresta* e *Urbano* com base na informação dos atributos associados aos objectos imagem. Posteriormente, será efectuada a classificação dos *Espaços verdes urbanos* (classe filha da classe *Floresta*), com base na análise do contexto urbano nomeadamente relações de vizinhança, utilizando a seguinte característica “limites de *Floresta* rodeados por objectos vizinhos *Urbanos*”. Para se proceder a este método, a classificação terá de ser um processo iterativo em ciclos, nos quais cada objecto é

classificado e reclassificado tendo em conta as alterações da classificação da rede de objectos.

Técnica de máscaras

A aplicação da técnica de máscara a uma determinada classe permite restringir o processo de classificação aos objectos imagem que a constituem.

Ao construir uma hierarquia de classes pode ser útil criar primeiro uma classe *a* que pertencem objectos que possuam propriedades que os distinguem claramente dos restantes. Como exemplo, pode-se começar por classificar todos os objectos que pertencem a uma classe *a* e em seguida criar uma classe *b* para cobrir todos os objectos que ficaram por classificar. Os objectos que pertencem à classe *b* serão todos aqueles que verificam a seguinte regra “não é classe *a*”. Ao ser criada uma classe *c* como classe filha da classe *b*, esta herdará as suas propriedades. Desta forma, as classes *a* e *b* passam a funcionar como máscaras a partir das quais se procede à análise separadamente. Sobre os objectos da imagem correspondentes a cada uma destas classes prossegue a classificação em sub-classes (figura 3.11). A técnica de máscaras será concretizada através de regras *fuzzy*.

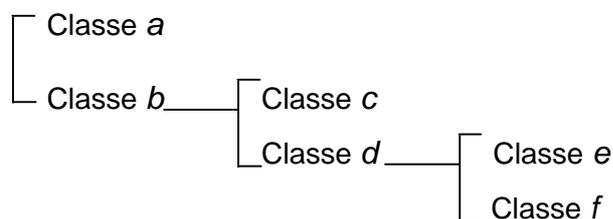


Figura 3.11 - Hierarquia de classes.

Classificação

No processo de classificação é estabelecida a ligação das classes da hierarquia com os objectos resultantes da imagem segmentada. O resultado da classificação é uma rede de objectos imagem classificados aos quais ficam associados atributos (graus de pertença a uma ou mais classes), relações entre os objectos e relações com as outras classes que constituem a hierarquia de classes.

A classificação pode ser efectuada com ou sem classes relacionadas. A classificação sem classes relacionadas é um processo determinístico e relativamente simples, em que cada objecto é atribuído a uma classe com um grau de pertença *fuzzy* calculado a partir da descrição da classe. A classe com o valor mais alto de pertença será atribuída como a

classificação do objecto imagem, se o valor de pertença exceder um valor mínimo pré-definido.

A classificação com classes relacionadas é mais complexa. A classificação é um processo iterativo, em ciclos, em que cada objecto é classificado sucessivamente tendo em atenção as alterações na classificação dos objectos que constituem a rede hierárquica. Este processo de classificação será utilizado quando se pretenda que a classificação atribuída a um objecto sirva de informação de contexto para a classificação de outros objectos. Após o processo da classificação, cada objecto é atribuído, ou não, a uma certa classe.

3.4 Avaliação da qualidade dos resultados obtidos

A avaliação da qualidade da classificação é de extrema importância na detecção remota, uma vez que, fornece evidências relativamente à capacidade do classificador para extrair os objectos ou a informação pretendida da imagem.

Para a validação do mapa produzido será utilizada uma amostra aleatória, a qual será constituída por 50 amostras por cada classe de informação extraída da imagem no processo de classificação, valor sugerido por Congalton (1999) como o número mínimo aconselhável. A unidade da amostra a utilizar será o objecto (polígono). Através de dados recolhidos no terreno será obtida a informação da verdadeira classificação relativa a estes dados de referência.

Os resultados da avaliação da precisão dos mapas são apresentados sob a forma de uma matriz de erro. Nas linhas da matriz serão representados os resultados da classificação e nas colunas os dados de referência.

Os índices utilizados para avaliar a precisão global do mapa são a medida global de concordância (OA, *overall accuracy*) e o índice *kappa*. A medida global de concordância consiste no quociente entre o somatório dos elementos da diagonal principal da matriz de confusão e o total de unidades utilizadas na validação. O índice *Kappa* representa uma medida da diferença entre a concordância "classificação efectuada e os dados de referência" e a concordância que se obteria com uma atribuição aleatória dos *pixels* às várias classes. Esta estatística serve como indicador para avaliar em que medida a percentagem de valores correctos, numa matriz de confusão, é devida à verdadeira concordância entre observações ou é devida à casualidade.

Os índices utilizados para estimar a precisão de cada classe são a precisão do utilizador e a precisão do produtor. A precisão do produtor permite saber, de entre as unidades da amostra identificadas no terreno, como pertencentes a uma dada classe, quais as que estão bem identificadas no mapa produzido. É obtida através do quociente entre o

número de unidades da amostra que foram correctamente atribuídas a uma dada classe e o número total de amostras que correspondem efectivamente a essa classe no terreno. A precisão do utilizador permite avaliar de entre a informação cartografada no mapa, qual é a que na realidade pertence à sua verdadeira classe. É obtida através do quociente entre o número de unidades da amostra que foram correctamente atribuídas a uma dada classe e o número total de unidades que na classificação foram atribuídas a essa classe, correcta ou incorrectamente.

3.5 Análise e visualização gráfica da incerteza temática

Apesar da matriz de confusão e as suas estatísticas apresentarem uma importante informação relativamente aos dados, esta abordagem não permite a representação da distribuição espacial da incerteza da classificação. A visualização da incerteza tem a vantagem de permitir melhorar a análise e o entendimento dos dados por parte do utilizador. Este é um processo relativamente recente e embora na última década várias investigações tenham sido efectuadas, conforme referido no capítulo 2, e existam já *softwares* de análise de imagem que facultam alguma quantificação desta incerteza, como o eCognition, o procedimento geral é utilizar estes parâmetros na melhoria da classificação. Essa informação não é fornecida ao utilizador dos dados e não se encontra ainda disponível nos *softwares* mais comercializados. No estudo apresentado foi realizado um esforço no sentido de conseguir efectuar uma representação espacial da incerteza, de forma a que esta possa ser utilizada pelo utilizador dos dados, para permitir saber o grau de confiança das zonas classificadas.

Quando se utiliza um método baseado em classificação *fuzzy*, os objectos podem pertencer a mais do que uma classe com diferentes graus de pertença conforme referido na secção 3.3.3. Isto acontece quando os conjuntos *fuzzy*, definidos pelas funções de pertença, que constituem a descrição das classes, se sobrepõem. Os objectos cujos valores característicos estão contidos na gama de valores sobrepostos, podem ser encarados como objectos ambíguos uma vez que servem o critério de mais do que uma classe. Esta ambiguidade não significa que os objectos estão mal classificados, mas antes que não existe nenhuma classe à qual esses objectos pertençam explicitamente.

No método a utilizar, os objectos serão atribuídos à classe relativamente à qual o grau de pertença é maior. No resultado da classificação ficará retida a informação relativamente ao melhor, ao segundo melhor e ao terceiro melhor grau de pertença.

Será com base nas estatísticas dos graus de pertença dos objectos atribuídos a cada classe, presentes no resultado da classificação, que será efectuada a análise da incerteza

dos resultados da classificação.

Um dos métodos de análise adoptado consistirá em: (1) quantificar, para cada classe, os objectos que tiverem apenas um grau de pertença com valor '1' (total pertença) a essa classe (quantos mais objectos tiverem apenas um grau de pertença de '1' a uma classe, melhor é a identificação da classe e vice - versa); (2) quantificar, relativamente a cada classe, os valores relativos ao maior grau de pertença com que os objectos foram atribuídos a essa classe; (3) efectuar uma comparação entre os graus de pertença para a melhor e a segunda melhor classificação.

A análise das estatísticas relativas aos graus de pertença dos objectos às classes permite avaliar a qualidade das classes. Por outro lado, a comparação entre os graus de pertença, para a melhor e a segunda melhor classe, permite avaliar a ambiguidade ou a incerteza, ou seja, a capacidade em separar os objectos. Por exemplo, se um objecto for atribuído à classe *Áreas residênciais contínuas* com um grau de pertença compreendido entre 1 e 0.9, para o melhor valor da classificação, e atribuído à classe *Áreas residênciais descontínuas* com um grau de pertença compreendido entre 0.9 e 0.8, para o segundo melhor valor da classificação, significa que existe ambiguidade ou incerteza, pois os valores são muito próximos.

Para caracterizar a incerteza temática será calculada a distribuição da frequência dos valores da probabilidade para a melhor e segunda melhor classificação. Para isso serão utilizados intervalos de probabilidade conforme ilustrado no quadro 3.2.

Quadro 3.2 - Distribuição da frequência de probabilidade.

Probabilidade do melhor valor da classificação (%)]90,100]]80,90]]70,80]		[0,70]			
Incerteza	Muita		Média	Pouca	Muita		Média	Pouca	Média	Pouca	Muita		
Probabilidade do segundo melhor valor da classificação (%)]90,100]]80,90]]70,80]]50,70]	[0,50]]80,90]]70,80]]50,70]	[0,50]]70,80]]50,70]	[0,50]	[0,70]

Ehlers e Wenzhong (1996) efectuaram, conforme referido na secção 2.2 do capítulo 2, a caracterização da incerteza temática calculando a distribuição da frequência de probabilidade, utilizando apenas o valor da máxima probabilidade da verosimilhança de cada *pixel*. No presente trabalho será caracterizada a incerteza temática com base na análise da distribuição da frequência de probabilidade do melhor e do segundo melhor valor da classificação, conforme se apresenta no quadro 3.2.

O objectivo é obter um mapa com informação espacial das zonas cuja classificação possui muita incerteza, incerteza média e pouca incerteza. Para isso serão definidos critérios com base nos intervalos de probabilidade, relativamente aos valores que serão

representativos da pouca, média ou muita incerteza (apresentados no quadro 3.2). Este mapa ao ser sobreposto ao mapa da classificação final, permitirá ao utilizador, em termos visuais, avaliar as várias zonas de incerteza na classificação.

3.6 Integração de dados SIG

Conforme acima referido, após recolha e avaliação da informação existente da área de estudo, pretende-se extrair da imagem de satélite as classes de informação que não existem ou, existindo, se encontrem desactualizadas. A informação de ocupação/uso do solo extraída da imagem, com base no método da análise de imagem orientada por objectos, será integrada, na fase pós-classificação, com os dados auxiliares previamente estruturados em ambiente SIG. Esta integração será efectuada num ambiente SIG vectorial.

CAPÍTULO 4 – Implementação da metodologia desenvolvida no Concelho da Marinha Grande

Neste capítulo a metodologia, desenvolvida e descrita no capítulo 3, é testada na produção de mapas de uso do solo à escala 1:10 000, numa área do Concelho da Marinha Grande. Primeiramente é feita a descrição da área de estudo e dos dados utilizados, nomeadamente as imagens de satélite e os dados auxiliares. Uma das etapas da metodologia consistiu na recolha da informação existente no Município da Marinha Grande com o objectivo, por um lado, de enriquecer a nomenclatura de referência e, por outro, de avaliar a informação que efectivamente era necessário extrair da imagem. Pretendia-se extrair apenas da imagem a informação que não existia ou se encontrava desactualizada face à nomenclatura de referência criada. Como na Câmara Municipal da Marinha Grande (CMMG) existe uma grande quantidade de informação, relativamente a todo o Concelho, optou-se por colocar mais ênfase na exploração da imagem para que os resultados pudessem ser extrapolados para outras áreas e noutros estudos e ignorou-se a informação existente. No final, contudo, introduziram-se alguns dados auxiliares para que o resultado ficasse mais enriquecido. Seguidamente são descritas as várias etapas da metodologia e apresentados os resultados obtidos, seguidos de discussão.

4.1 Área de estudo

A área escolhida para a realização do estudo localiza-se no Concelho da Marinha Grande (figura 4.1), mais especificamente na zona com maior densidade populacional e onde se registaram as maiores alterações a nível de ocupação do solo, segundo dados da CMMG.

A área territorial do Concelho da Marinha Grande confronta a Norte e a Este com o Concelho de Leiria, a Sul com o Concelho de Alcobaça e a Oeste estende-se paralelamente à Costa Atlântica, pelo que, as praias, as dunas, a forte influência marítima e o fraco relevo, que varia entre valores de 47m e 110m de cota, constituem algumas das suas características marcantes.

Duas outras componentes que caracterizam este Concelho são a sua enorme riqueza em termos de área florestal e a sua enorme dinâmica industrial (destacando-se a indústria vidreira e a indústria de moldes que constituem o principal sector da actividade económica).

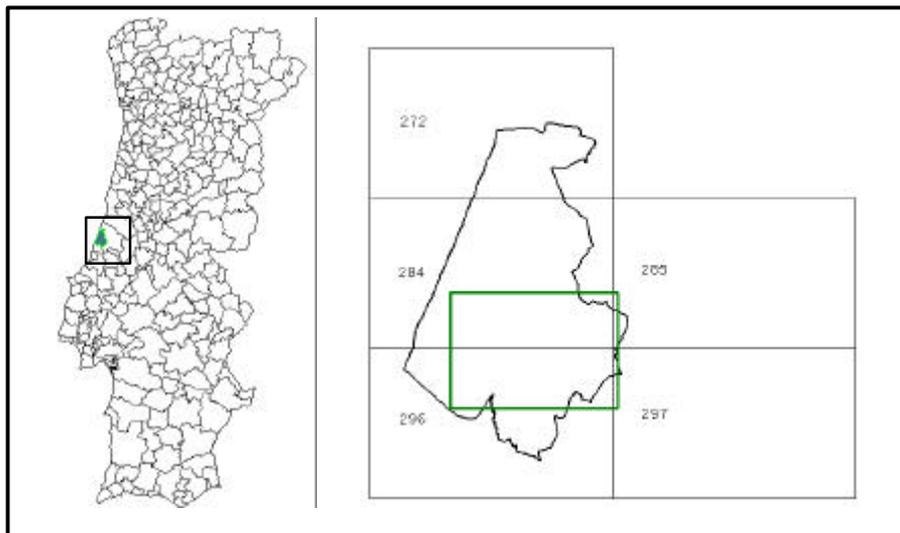


Figura 4.1 - Localização do limite administrativo do Concelho da Marinha Grande e área de estudo (rectângulo verde). As folhas apresentadas são as da Carta Militar produzidas pelo Instituto Geográfico do Exército (escala 1:25 000) do respectivo Concelho.

Relativamente à sua área florestal, é de salientar que a Marinha Grande é um dos Concelhos do país com maior taxa de arborização (77%), apresentando ainda a particularidade da maior parte da área florestal ser pública (mais de 80% da floresta do Concelho), sendo administrada pela Direcção Regional de Agricultura da Beira Litoral (DRABL), segundo dados obtidos a partir de um estudo efectuado para a CMMG em 1996 pela empresa Geoterra. Este facto tem possibilitado uma gestão mais homogénea e orientada para a maximização da produção a longo prazo, ao contrário do que sucede na área privada envolvente, caracterizada por parcelas minifundiárias, o que dá origem a um mosaico de ocupação do solo heterogéneo. O pinheiro bravo é a espécie predominante da mancha florestal do Concelho. Segundo o estudo acima citado, em 1996 ocupava 68% da área florestal seguido do eucalipto com 5,7%.

A figura 4.2 apresenta a localização da Mata Nacional de Leiria e Mata do Casal da Lebre, sob a administração da DRABL, no Concelho da Marinha Grande.

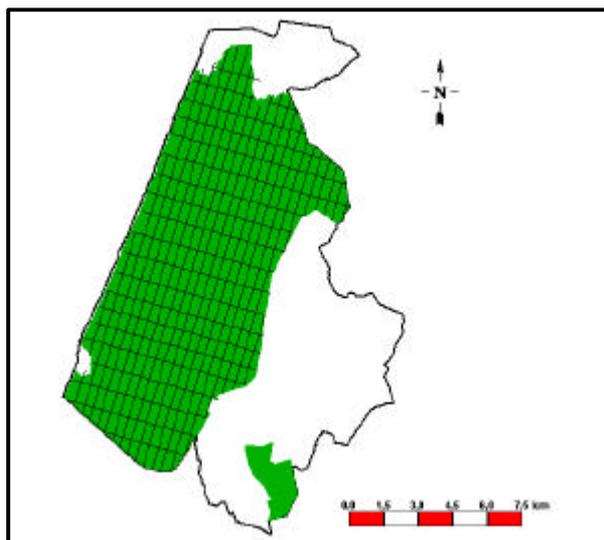


Figura 4.2 - Localização do limite da Mata Nacional de Leiria e Mata do Casal da Lebre, sob a administração da DRABL, face ao limite administrativo do Concelho da Marinha Grande.

4.2 Base de dados

4.2.1 Imagens de satélite

Os dados imagem utilizados no trabalho são as imagens CARTERRA™ GEO obtidas a partir do sensor IKONOS-2 no modo pancromático (Pan), com uma resolução espacial de 1m, e no modo multiespectral (XS), com resolução espacial de 4m. Apresentam-se no quadro 4.1 as características das imagens utilizadas.

Quadro 4.1 - Características das imagens utilizadas.

Data de aquisição	2000/09/02
Hora de aquisição	11h 14 m
Ângulo de elevação solar (graus)	53.37588
Valor nominal da elevação solar (graus)	81.06776
Ângulo azimutal solar (graus)	145.0290
Valor nominal do azimute solar (graus)	50.9100
Banda 1 (azul)	0.45 μ m - 0.52 μ m
Banda 2 (verde)	0.52 μ m - 0.60 μ m
Banda 3 (vermelho)	0.63 μ m - 0.69 μ m
Banda 4 (infravermelho próximo)	0.76 μ m - 0.90 μ m
Pancromático	0.45 μ m - 0.90 μ m
Resolução espacial	1m (Pancro)
	4m (XS)
Resolução radiométrica	8 bits

Na figura 4.3 apresenta-se a localização da área abrangida pela imagem de satélite relativamente ao limite administrativo do Concelho e à Mata Nacional de Leiria.

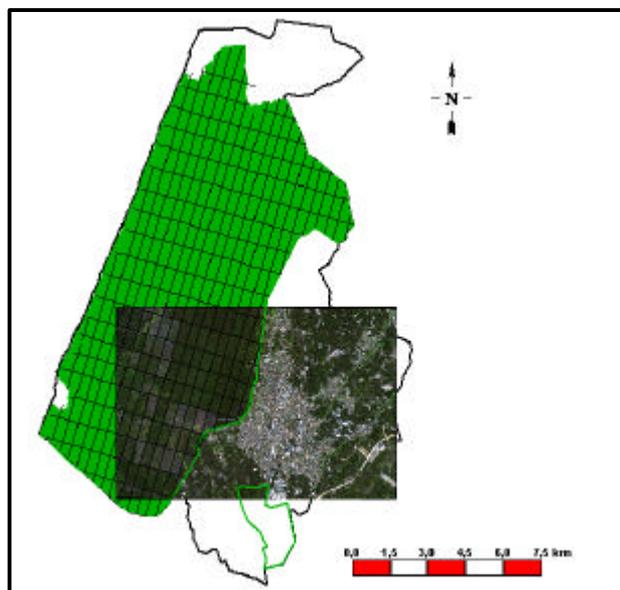


Figura 4.3 - Localização da área abrangida pela imagem de satélite relativamente ao limite administrativo do Concelho e à Mata Nacional de Leiria.

4.2.2 Dados auxiliares

No quadro 4.2 são apresentados os dados auxiliares utilizados no âmbito deste estudo caracterizados com base na escala, data de aquisição e produtor dos dados. Toda a informação referida no quadro 4.2 encontra-se em formato digital. Parte da informação foi organizada e inserida num Sistema de Informação Geográfica vectorial. O tratamento da informação e a estrutura dos conteúdos do modelo geográfico concebido são apresentados na secção 4.3.

Quadro 4.2 - Dados auxiliares.

Tipo de dados	Aquisição		Produtor
	Data	Escala	
Cartografia planimétrica	1996	1:2 000	GEOTERRA
		1:25 000	IGeoE
Espaços verdes	2000	1:2 000	CMMG
Etar	2000	1:2 000	CMMG
Infra-estruturas desportivas	2001	1:2 000	CMMG
Actividades económicas	2001	1:2 000	CMMG
Equipamento escolar	2001	1:2000	CMMG
Serviços de utilidade pública e adm. local	2001	1:2000	CMMG
Rede viária	2001	1:2000	CMMG
Património	2001	1:2000	CMMG
Carta florestal	1996	1:25 000	GEOTERRA
Carta de Ocupação do Solo 1990	1990	1:25 000	CNIG

IGeoE- Instituto Geográfico do Exército

CNIG –Centro Nacional de Informação Geográfica

Os dados auxiliares foram importantes nas várias fases da execução do trabalho. No quadro 4.3 é apresentado um breve resumo da utilidade dos dados auxiliares.

Quadro 4.3 - Resumo da utilidade dos dados auxiliares.

Tipo de dados	Utilidade
Dados cartográficos planimétricos	Rectificação e geo-referênciação das imagens de satélite
Espaços verdes	Auxiliar na avaliação da qualidade do mapa de ocupação do solo
Rede viária, Equipamento escolar, Infra-estuturas desportivas, Actividades económicas, Património, Serviços de utilidade pública e administração local, Etar	Melhoramento dos mapas produzidos com base na classificação espectral
Dados recolhidos em trabalho de campo	Auxiliar na definição de áreas de treino e na avaliação da qualidade dos mapas de uso do solo
Carta de Ocupação do Solo 1990	Auxiliar na avaliação qualitativa da classificação espectral efectuada e análise da dinâmica da ocupação do território.

4.3 Estruturação e introdução dos dados recolhidos no município num sistema de informação geográfica

Neste estudo não será apresentado o projecto de concepção e a estrutura da informação do modelo de dados geográfico concebido pela autora para o Concelho da Marinha Grande, pois sai fora dos objectivos do estudo (Gonçalves *et al.*, 2002). Dada a quantidade de informação existente sobre a área de estudo relativamente às áreas urbanas, conforme já referido, optou-se por dar mais ênfase à exploração das imagens, o que no caso da Marinha Grande também é útil pois permitiu avaliar a informação que se pode extrair para que, futuramente, possa constituir uma fonte de dados para actualização dessa mesma informação.

As linhas de acção empreendidas na concepção do projecto SIG, que incidiu sobre a área de estudo, foram as seguintes: (1) criação do projecto e dos respectivos ficheiros; (2) estruturação de conteúdos do modelo de dados; (3) criação da base de dados geográfica.

Para que a informação cartográfica existente pudesse ser importada para um ambiente SIG foi necessário proceder à sua preparação. A cartografia urbana de base existente na CMMG encontrava-se no formato digital, contudo os ficheiros não possuíam as mesmas unidades de trabalho e a informação não estava separada por camadas, tendo sido necessária a definição das unidades de trabalho e a organização dos respectivos ficheiros. Relativamente à definição do sistema de referência espacial, mantiveram-se os parâmetros cartográficos do sistema de referência da cartografia da CMMG: Projecção Gauss-Kruger; Datum Geodésico Lisboa (Castelo S. Jorge); Elipsoide Hayford, ponto central e origem do sistema de coordenadas no vértice geodésico da Melriça.

Para o projecto de arquitectura do sistema SIG foi definido primeiramente a estrutura padrão dos conteúdos (anexo 3) e a organização da base de dados geográfica. A definição da estrutura padrão teve um objectivo mais amplo, ou seja, pretendeu-se construir uma estrutura que servisse também uma vasta gama de utilizações a nível municipal (podendo ser expandida ou ampliada). Esta base de dados contém, por exemplo, informação identificada como de interesse comum a vários serviços, nomeadamente: níveis de informação topográfica de base, delimitação de áreas administrativas, gestão urbanística, rede viária e roteiro toponímico. Para além desta informação considerada de interesse comum, o conteúdo da base de dados inclui também, a título de exemplo, inventário de redes de infra-estruturas, inventário do equipamento escolar, desportivo, social e cultural, inventário do património municipal, usos potenciais do solo.

O quadro 4.4 apresenta apenas o conteúdo e a estruturação da informação na base de dados que se optou por integrar na etapa final, com a classificação efectuada. Esta

integração será realizada por sobreposição dos vários temas. No anexo 4 são descritos com mais pormenor os elementos gráficos, as entidades e as tabelas de atributos, bem como o tipo de relações estabelecidas entre tabelas.

Quadro 4.4 - Conteúdo e estruturação da informação do modelo geográfico utilizada no estudo.

Conteúdo da base de dados	Unidade mínima de referência espacial	Processo de referência
Informação cartográfica planimétrica	Edificado	Área
Equipamento escolar	Edifício e o limite de propriedade	Área/Ponto
Recintos desportivos	Equipamento desportivo	Área/Ponto
Etar	Limite de propriedade	Área
Actividades económicas	Edifício	Área
Rede viária	Troço de via	Linha/Área
Serviços de utilidade pública e administração local	Edifício	Área
Património	Edifício	Área/Ponto
Carta florestal 1996	Classe de ocupação e uso do solo	Área

4.4 Software

O pré-processamento das imagens, nomeadamente a geo-referênciação, foi efectuada utilizando o *software Image Analyst 7.03 da Intergraph*. A análise da imagem orientada por objectos foi executada utilizando o *software eCognition 1.0 da Dephiniens*. Para a digitalização da informação e ligação da informação alfanumérica à informação gráfica utilizou-se o *software GeomediaPro 4.1*. As operações de análise espacial e conversão do formato *raster* para o formato vectorial foram efectuadas com o *software ArcView 3.2*.

4.5. Pré - processamento dos dados

4.5.1. Correção geométrica

A correcção geométrica da imagem pancromática e multiespectral foi efectuada realizando uma transformação afim entre a geometria da imagem e uma geometria de referência definida pelo sistema de geo-referência da cartografia urbana de base existente na CMMG. Para tal foram seleccionados pontos de controle na imagem e na cartografia à escala 1:2 000, à custa dos quais foi calculado, por um ajustamento por mínimos quadrados,

o polinómio da transformação afim. O método de reamostragem da imagem utilizado foi o do *vizinho mais próximo* (Richards, 1986). Foram seleccionados 51 pontos de controle para a imagem pancromática e 30 pontos para a imagem multiespectral, distribuídos pelas imagens o mais uniformemente possível (quadro 4.5).

O erro médio quadrático obtido para a correcção geométrica da imagem pancromática foi de 0.49 m e para a imagem multiespectral de 1.95 m, ou seja, erros inferiores a metade do *píxel*, o que garante uma correcta geo-referênciação. Os valores referidos são apresentados no quadro 4.5. Para ilustrar a qualidade da geo-referênciação efectuada é a apresentada, nas figuras 4.4 e 4.5, a sobreposição da cartografia urbana com as imagens geo-referênciaadas.

Quadro 4.5 - Caracterização da correcção geométrica.

Data	Imagem	N.º pontos controle	Erro médio quadrático (m)
02/09/2000	Pancromática	51	0.49
02/09/2000	Multiespectral	30	1.95

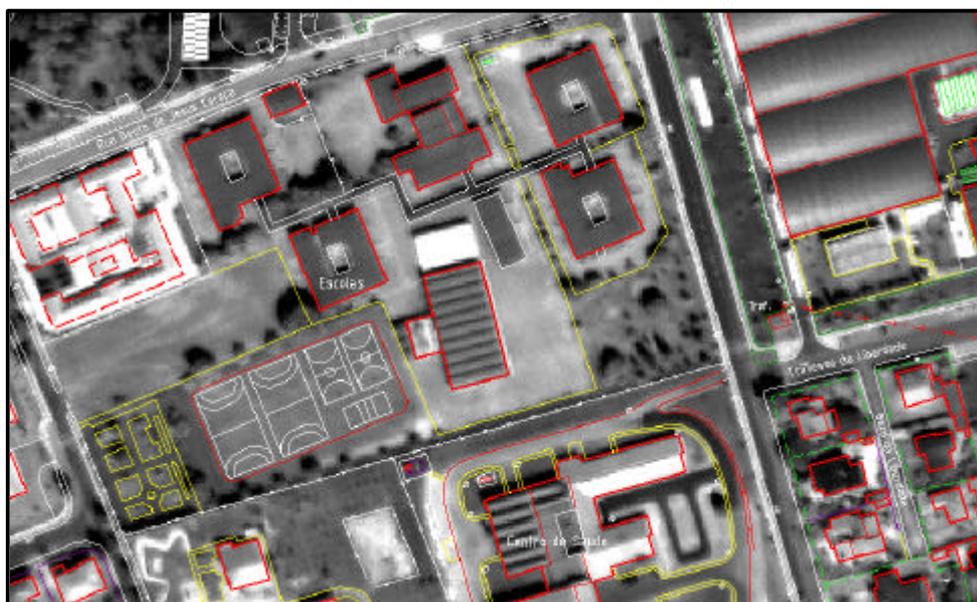


Figura 4.4 - Sobreposição da imagem IKONOS pancromática geo-referênciaada com a cartografia à escala 1:2000 da CMMG.

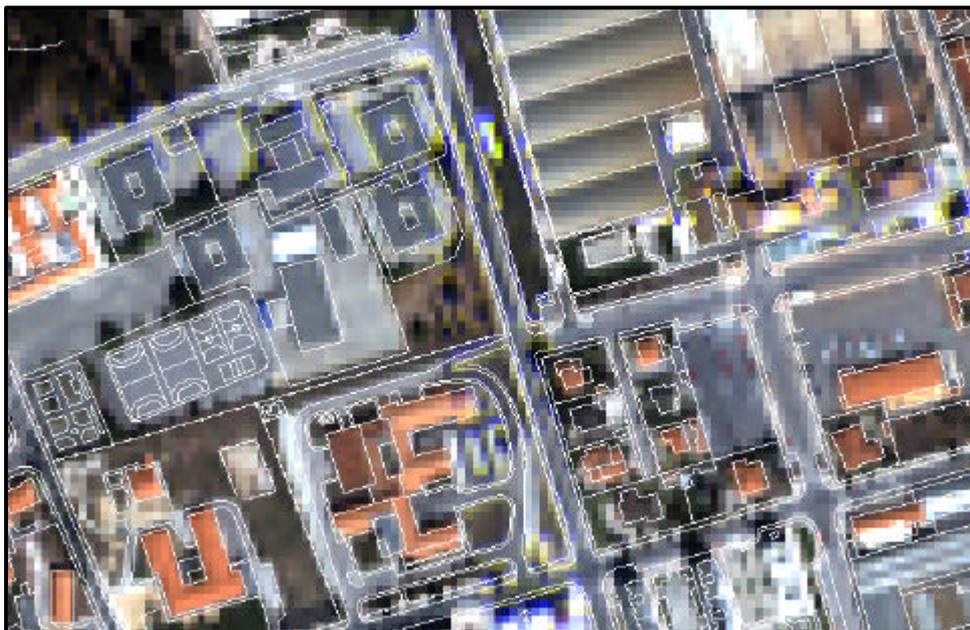


Figura 4.5 - Sobreposição da imagem IKONOS multiespectral geo-referenciada (RGB 321) com a cartografia à escala 1:2000 da CMMG.

4.5.2 Correção atmosférica

A distorção radiométrica mais importante em imagens de detecção remota, relativas a áreas planas, deve-se ao efeito da atmosfera. Contudo, se a atmosfera tiver um efeito uniforme nos dados pode inferir-se que é uniforme em toda a área de estudo (Kaufman, 1984). Como o relevo da área de estudo é praticamente plano, variando entre 47m e 110m de cota, foi apenas efectuada uma análise dos dados imagem para verificar se o efeito da atmosfera é uniforme.

A energia electromagnética, ao atravessar a atmosfera, fica sujeita a efeitos de dispersão que actuam selectivamente em relação a determinados comprimentos de onda, fazendo-se sentir nos canais ou bandas que correspondem às gamas dos comprimentos de onda mais curtos. Assim, para efectuar a análise acima referida, dividiu-se a imagem correspondente à banda do azul em duas partes iguais e foram analisados os valores radiométricos mínimos em cada uma delas. Os valores obtidos, apresentados no quadro 4.6, revelam que a sua distribuição é uniforme em toda a imagem e, conseqüentemente, a atmosfera será uniforme em toda a área de estudo. Como em estudos unitemporais, sem efeito topográfico significativo e com atmosfera uniforme nos dados imagem, se pode trabalhar sem qualquer correção radiométrica, pois esta não irá melhorar os resultados (Caetano, 1995), no estudo optou-se por não proceder a nenhuma correção radiométrica.

Quadro 4.6 - Valores radiométricos máximos e mínimos obtidos em duas partes iguais da imagem na banda do azul.

Estatísticas	Banda azul 1	Banda azul 2
Mínimo	22	23
Máximo	155	157

4.6 Análise exploratória dos dados

No início do estudo foi efectuada uma análise exploratória dos dados. Nos quadros 4.7 e 4.8 apresenta-se a caracterização estatística das quatro bandas multiespectrais e da banda pancromática.

Quadro 4.7 - Resultados da análise estatística dos níveis radiométricos das 4 bandas multiespectrais da banda pancromática da imagem utilizada.

Estatísticas	Banda azul	Banda verde	Banda vermelho	Banda Infravermelho próximo	Pancromática
Média	29.6	30.5	23.9	46.4	34.2
Mediana	26	25	17	43	30
Desvio Padrão	9.5	14.6	16.4	14.4	12.2
Mínimo	21	16	8	9	14
Máximo	231	252	244	246	193

Quadro 4.8 - Matriz de correlação entre as 4 bandas da IKONOS 2000.

Correlação bandas IKONOS 2000	Banda azul	Banda Verde	Banda vermelho	Banda infravermelho próximo
Banda azul	1			
Banda verde	0.97	1		
Banda vermelho	0.93	0.98	1	
Banda infravermelho próximo	0.62	0.70	0.70	1

Dos dados obtidos na matriz de correlação conclui-se que as bandas azul e infravermelho próximo são as que apresentam menor redundância de informação.

4.7 Extracção da informação temática a partir dos dados imagem

Para a extracção da informação temática a partir da imagem de satélite, a metodologia adoptada envolveu quatro etapas distintas: (1) esquema de classificação; (2) segmentação da imagem para criação dos objectos imagem; (3) construção da base de conhecimento estruturada sob a forma de um hierarquia de classes; (4) classificação dos objectos.

Nesta secção, serão apresentados os resultados obtidos em cada uma das etapas acima referidas seguidos de discussão.

4.7.1 Esquema de classificação

No âmbito deste estudo foi estabelecido um esquema de classificação, composto por 30 classes, que consistiu, no essencial, na adaptação, para os níveis das Áreas artificiais, da nomenclatura CLUSTERS e, para os restantes níveis, na adaptação da nomenclatura CORINE Land Cover (anexo 1). A principal diferença entre a nomenclatura estabelecida e as nomenclaturas referidas consiste na inclusão de uma nova classe designada de Áreas corte floresta (43). A nomenclatura apresenta quatro níveis de detalhe para as Áreas artificiais, três níveis para os Meios semi-naturais e dois níveis para Áreas com ocupação agrícola, Floresta, Meios aquáticos e Superfícies com água. Como a imagem IKONOS é de Setembro, tem apenas uma banda na zona do infravermelho próximo, e se trata de um estudo unitemporal, a análise exploratória deverá incidir mais nas áreas urbanas, pelo que a nomenclatura apresenta um maior número de níveis de detalhe relativamente às Áreas artificiais. Contudo, ao estabelecer a nomenclatura, procurou-se que esta cumprisse as condições referidas por Freire *et al.* (2001): (1) organização hierárquica compatível com as nomenclaturas nacionais; (2) permitir a comparação com outras fontes de informação sobre uso e ocupação do solo; (3) compatibilidade com classificação CORINE Land Cover; (4) utilidade para um maior número possível de estudos e aplicações.

Após o esquema estabelecido (anexo 1), foi efectuada uma análise das classes de informação que existiam na área de estudo, com base no conhecimento do analista. Das 30 classes da nomenclatura, existem apenas 22 classes de informação na área de estudo. Esta etapa é muito importante pois reduziu o universo da análise. No quadro 4.9 é apresentado o esquema de nomenclatura contendo, apenas, das classes de informação que constituíam o esquema inicialmente estabelecido, as que existem na área de estudo.

Quadro 4.9 - Nomenclatura de ocupação do solo resultante da análise das classes de informação, existentes na área de estudo.

NIVEL I	NIVEL II	NIVEL III	NIVEL IV	
1 Áreas artificiais	11 Zonas com dominância de habitação	111 Áreas residenciais	1111 Áreas residenciais contínuas	
			1112 Áreas residenciais descontínuas	
		112 Serviços de utilidade pública e administração local		
	12 Zonas com revestimento predominantemente artificializado	121 Espaços de actividades industriais, comerciais e equipamentos gerais	1211 Zonas industriais	1212 Zonas comerciais e financeiras
		122 Infra-estruturas da rede viária e da rede ferroviária	1221 Rede viária	1222 Rede ferroviária
	13 Zonas alteradas artificialmente sem vegetação	131 Pedreiras, saibreiras		
		132 Descargas industriais e zonas de lixeiras e depósitos de sucata		
		133 Estaleiros		
		134 Etar		
	14 Zonas verdes ordenadas	141 Espaços verdes urbanos		
		142 Infra-estruturas desportivas		
		143 Zonas históricas e espaços culturais		
2 Áreas com ocupação agrícola	21 Áreas agrícolas com culturas anuais			
	22 Culturas permanentes			
	24 Zonas agrícolas heterogéneas			
3 Floresta	31 Folhosas			
	32 Resinosas			
	33 Povoamento florestal misto			
4 Meios semi-naturais	41 Zonas com vegetação arbustiva e herbácea			
	43 Áreas corte floresta			

4.7.2. Segmentação da imagem

Para efectuar a análise da imagem utilizando uma abordagem orientada por objectos é necessário, como acima referido, proceder primeiro à sua segmentação para extrair os objectos imagem.

Numa primeira fase, foram executados vários testes com as imagens pancromática, multiespectral e a fusão das duas imagens. A fusão das imagens tem sido utilizada com sucesso por alguns autores na extracção de informação de áreas urbanas (e.g., Hofmman, 2001a). No estudo realizado, optou-se por não proceder ao seu uso devido ao ‘peso’ do

ponto de vista computacional que a sua utilização implicava, impossibilitando a utilização de toda a imagem. Assim, as imagens utilizadas na fase da segmentação, para a realização do estudo, foram as quatro bandas multiespectrais do satélite IKONOS: banda 1 (azul); banda 2 (verde); banda 3 (vermelho); banda 4 (infravermelho próximo).

Tendo em conta os testes realizados constatou-se que não era possível extrair toda a informação da cobertura do solo com base na nomenclatura de referência, apenas com uma única segmentação da imagem. Foi necessário efectuar várias segmentações, que foram guardadas em níveis diferentes, para possibilitar que os objectos de diferentes níveis de segmentação e com diferentes significados (em termos espaciais) fossem combinados no processo de classificação.

No trabalho realizado foram efectuadas quatro segmentações da imagem (figura 4.6). A razão de efectuar quatro segmentações prendeu-se, para além dos motivos acima referidos, com as seguintes razões: (1) obter uma imagem cujos objectos tivessem um tamanho próximo do *pixel*, para que pudesse servir como um nível de textura; (2) obter uma imagem cujo tamanho mínimo dos objectos estivesse de acordo com a escala de interesse; (3) gerar imagens que permitissem identificar as estruturas que se mantêm inalteráveis para determinadas variações de escala e que fossem representadas apenas por um único objecto imagem bem ajustado à forma do objecto real.

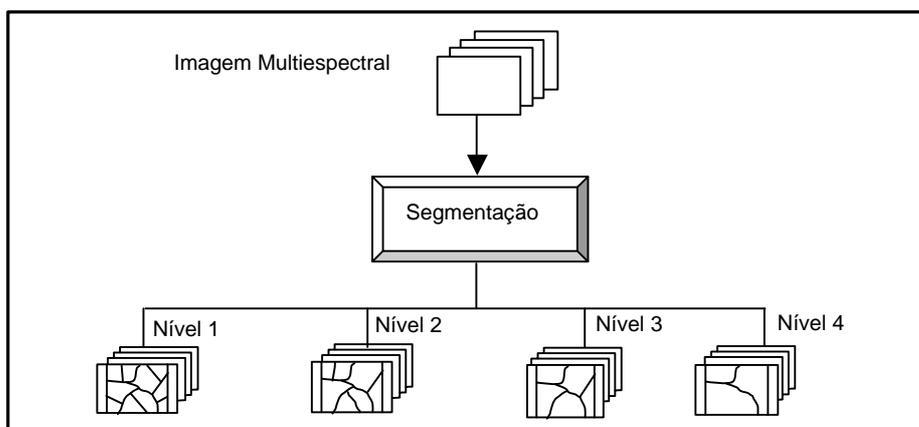


Figura 4.6 - Esquema da segmentação multi-resolução.

A extracção de objectos imagem é controlada por vários parâmetros, nomeadamente peso dos canais ou bandas, escala, cor, forma, suavização, compacidade e o nível em que é guardada, ou registada, a imagem segmentada. A escolha do valor a atribuir a cada um destes parâmetros é efectuada pelo utilizador. Relativamente ao valor a atribuir ao peso das bandas, este só pode tomar o valor 0 (nenhum peso) ou 1 (peso total). Os restantes parâmetros podem assumir valores no intervalo $[0,1]$, com excepção da escala que pode assumir valores de $[0, +\infty[$.

Inicialmente foram efectuados vários testes em que foram atribuídos diferentes valores aos vários parâmetros. A escolha dos valores adoptados está relacionada com várias razões que seguidamente se apresentam:

- relativamente ao parâmetro *peso das bandas*, foi atribuído o mesmo valor às quatro bandas do satélite IKONOS, pois têm a mesma resolução espacial e radiométrica.
- os valores atribuídos ao parâmetro *escala* estão intimamente ligados aos motivos pelos quais se optou por efectuar quatro segmentações da imagem.
- os valores para o parâmetro da *cor versus forma*, tiveram como objectivo: (1) gerar objectos uniformes em termos de área; (2) gerar objectos ajustados aos contornos dos objectos reais.
- para a *suavização versus compacidade* optou-se por atribuir o mesmo valor a ambos os parâmetros. Esta opção resultou de não se terem constatado alterações significativas no resultado da segmentação das imagens IKONOS, após a atribuição de valores diferentes.
- o resultado de cada segmentação foi registado num nível separado, para se poder estabelecer uma relação entre objectos de níveis diferentes (construção de uma rede hierárquica).

No quadro 4.10 apresentam-se os valores atribuídos aos vários parâmetros.

Quadro 4.10 - Valores dos parâmetros atribuídos na fase da segmentação.

Nível	Peso das bandas	Escala	Cor	Forma	Suavização	Compacidade
1	1	2	0.2	0.8	0.5	0.5
2	1	10	0.2	0.8	0.5	0.5
3	1	35	0.2	0.8	0.5	0.5
4	1	150	0.9	0.1	0.5	0.5

As quatro segmentações foram efectuadas segundo uma determinada sequência, tendo-se obtido primeiro a segmentação da imagem constituída por objectos mais pequenos, cuja área mínima é de 16 m² e a área média é de 128 m² e cujo resultado foi registado no nível 1 (quadro 4.11). As segmentações registadas nos níveis superiores são constituídas por objectos sucessivamente maiores. A imagem segmentada e registada no nível 2 corresponde a uma imagem constituída por objectos cuja área mínima está relacionada com a escala de interesse que é a escala 1:10 000. Anderson *et al.* (1976), recomendam que a unidade de área mínima seja definida por um quadrado de 2.5 mm de lado à escala de produção, para que tenha legibilidade (625 m² à escala 1:10 000). Portugal (1992), considera que a área mínima seja definida por um quadrado com 6 mm de lado (3600 m² à escala 1:10 000). O Instituto Geográfico Português (IGP) refere, nas

especificações do caderno de encargos da série cartográfica nacional 1:10 000, que sejam considerados elementos pontuais todos aqueles cuja área seja inferior a 20 m². A maioria das classes do nível 4 da nomenclatura estabelecida, como por exemplo, Infra-estruturas desportivas, Zonas industriais e Etar, têm áreas inferiores a 625 m² e a 3600 m², mas superiores a 20 m², pelo que a sua representação tem por isso legibilidade à escala 1:10 000. Pelo exposto, no estudo optou-se pelas directivas do IGP embora estas sejam mais direccionadas para a representação cartográfica. No quadro 4.11 é apresentado o tamanho mínimo e médio dos objectos gerados, em cada um dos níveis.

Quadro 4.11 - Número de objectos gerados em cada imagem segmentada e tamanho mínimo correspondente.

Nível	Nº de objectos	Tamanho mínimo(m ²)	Tamanho médio(m ²)
1	662 340	16	128
2	17 979	64	4528
3	2843	544	26512
4	178	4256	445152

A avaliação dos resultados da segmentação foi feita analisando visualmente o ajustamento para toda a área de estudo dos objectos imagem gerados. Para demonstrar a eficácia do método de segmentação, aplicado com os parâmetros adoptados, é apresentado na figura 4.7 o resultado das quatro segmentações efectuadas correspondentes a um extracto de uma zona urbana da imagem IKONOS. A figura 4.8 apresenta, relativamente à mesma área, o contorno dos objectos imagem obtidos, representados a vermelho, registados nos níveis 2, 3 e 4.

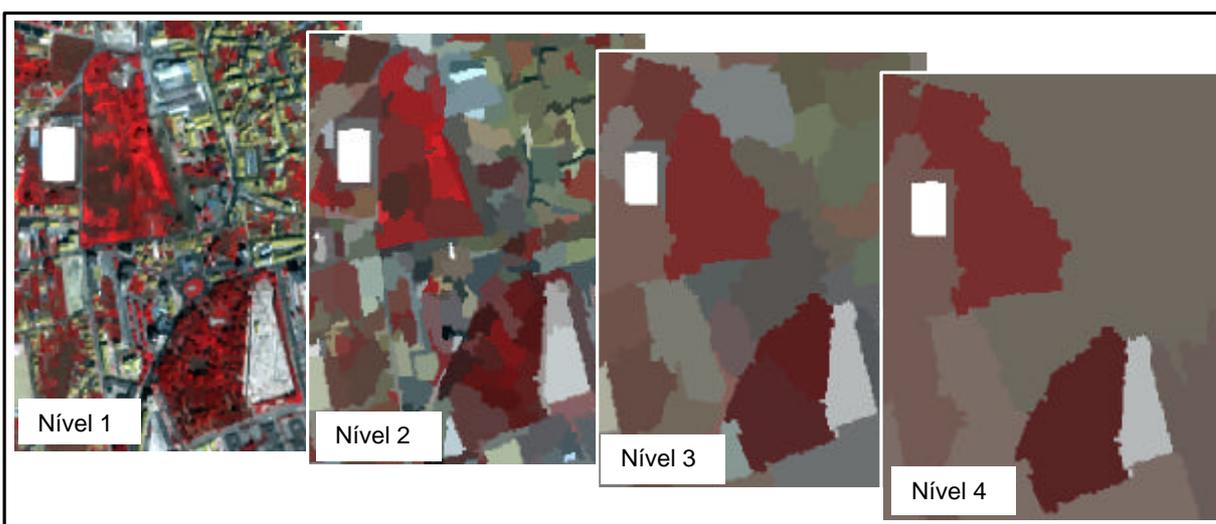


Figura 4.7 - Extracto com o resultado das quatro segmentações efectuadas com a imagem IKONOS (RGB 421), apresentando estruturas que se mantêm inalteráveis com a variação de escala e que são representadas apenas por um único objecto imagem.

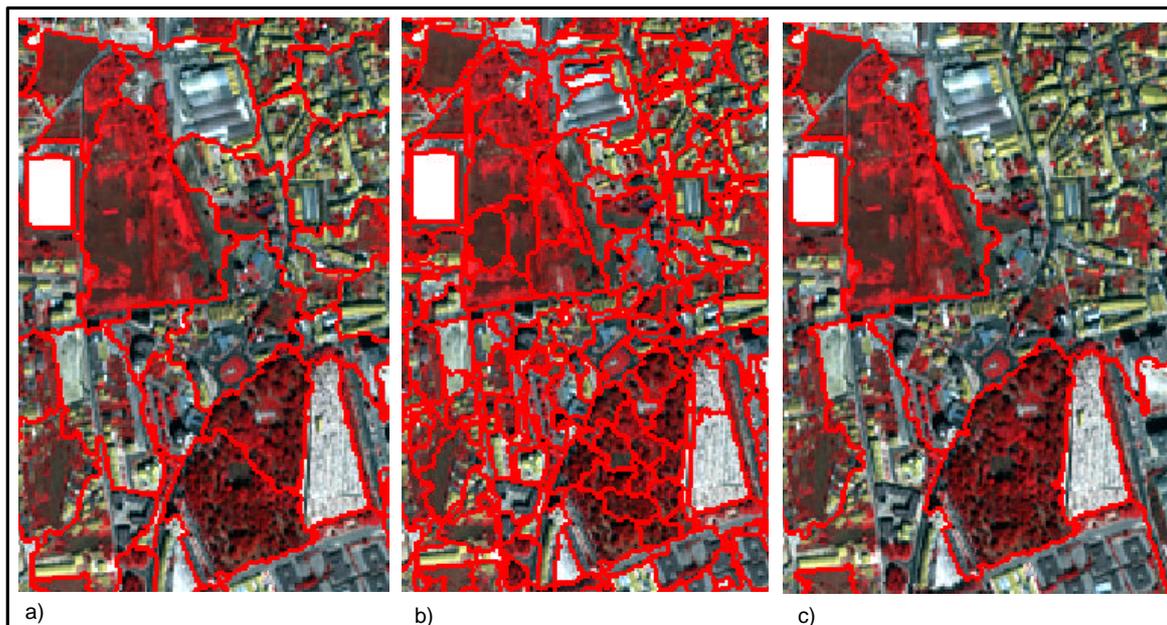


Figura 4.8 - Extracto da imagem IKONOS (RGB 421) com a sobreposição dos contornos dos objectos (representados a vermelho) resultantes de três segmentações efectuadas: Fig. 4.8 a) Segmentação do nível 2; Fig. 4.8 b) Segmentação do nível 3; Fig. 4.8 c) Segmentação do nível 4.

Comparando as imagens apresentadas nas figuras 4.7 e 4.8, verifica-se a existência de objectos imagem, correspondentes a campo de jogos, espaço verde e cemitério, que se mantêm inalteráveis para determinadas variações de escala e cujos contornos se apresentam ajustados à forma dos objectos reais. Estes são também alguns exemplos de objectos que foram possíveis de extrair logo nos níveis 3 e 4 e em que existe menos confusão espectral.

Na figura 4.9 podem-se observar algumas das manchas florestais existentes na área de estudo, rodeadas de área predominantemente urbana devido ao seu crescimento, ou pequenos núcleos urbanos rodeados de floresta, em que os objectos gerados com a segmentação realizada e registada no nível 4 (representados a amarelo), estão bem ajustados a esses contornos.

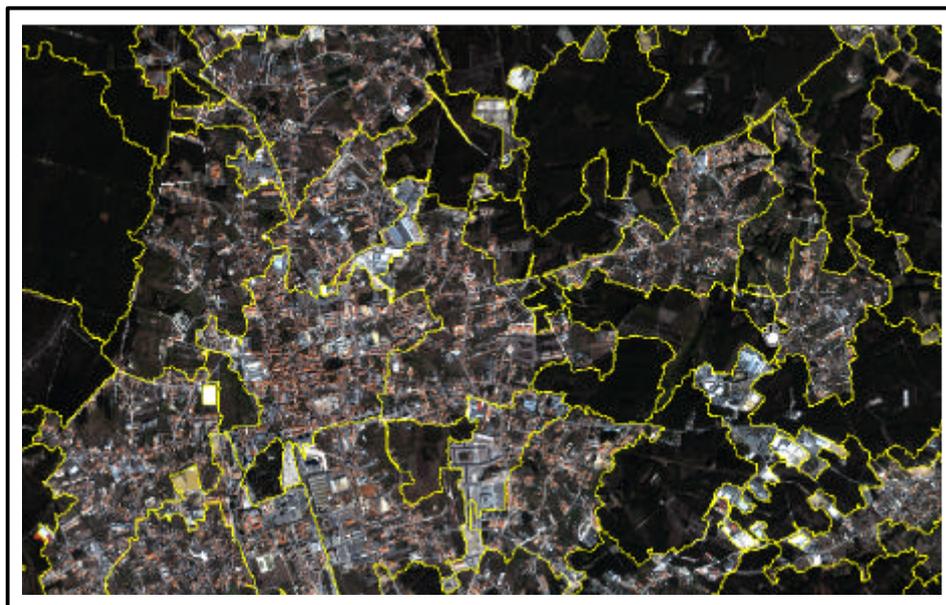


Figura 4.9 - Área da imagem IKONOS (RGB 321) com a sobreposição dos contornos dos objectos, obtidos com a segmentação realizada no nível 4, representados a amarelo.

Com a segmentação registada no nível 2, os objectos imagem já se apresentam ajustados aos contornos dos quarteirões, à estrutura dos grandes edifícios (figura 4.10) e às áreas de ocupação agrícola (figura 4.11).

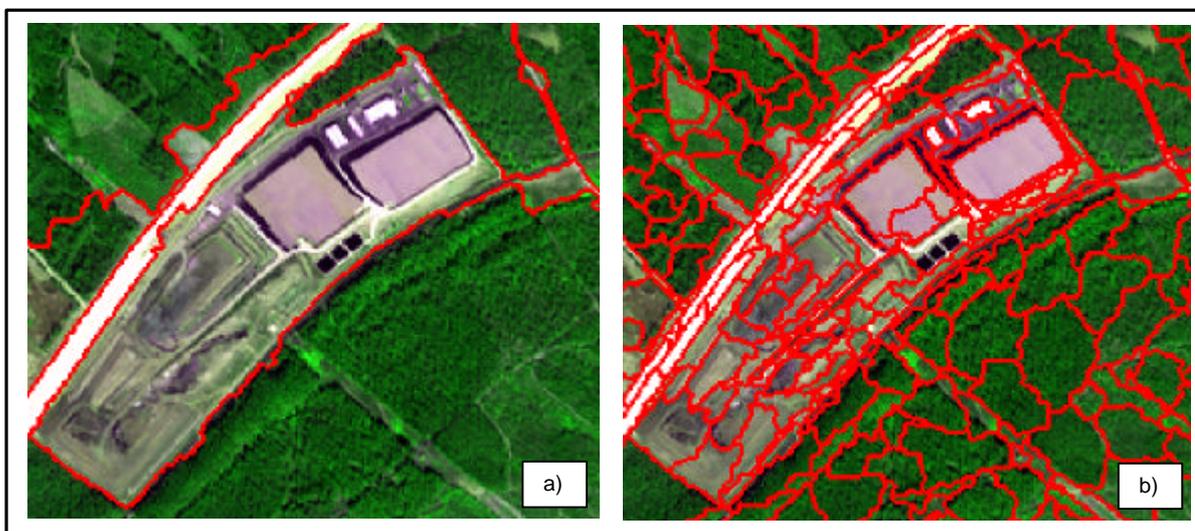


Figura 4.10 - Área da imagem IKONOS (RGB 341) relativa à zona do aterro lixeira com a sobreposição dos contornos dos objectos, gerados na segmentação, apresentados a vermelho: Fig. 4.10 a) Segmentação do nível 4, em que o objecto imagem gerado se apresenta ajustado a toda a estrutura do aterro lixeira; Fig. 4.10 b) Segmentação do nível 2, em que os objectos formados já permitem individualizar as estruturas dos edifícios.

A zona agrícola existente na área de estudo é constituída por parcelas pequenas inseridas, na sua maioria, na zona urbana menos densa ou na sua periferia. Por esta razão,

nas imagens segmentadas obtidas nos níveis 3 e 4, as áreas com ocupação agrícola estão inseridas nos objectos que contêm também área artificial (figura 4.11 a)). Na segmentação registada no nível 2, constituída por objectos mais pequenos, estes já se apresentam ajustados às áreas agrícolas, conforme se pode constatar na figura 4.11 b), permitindo a extracção da sua informação na fase de classificação.

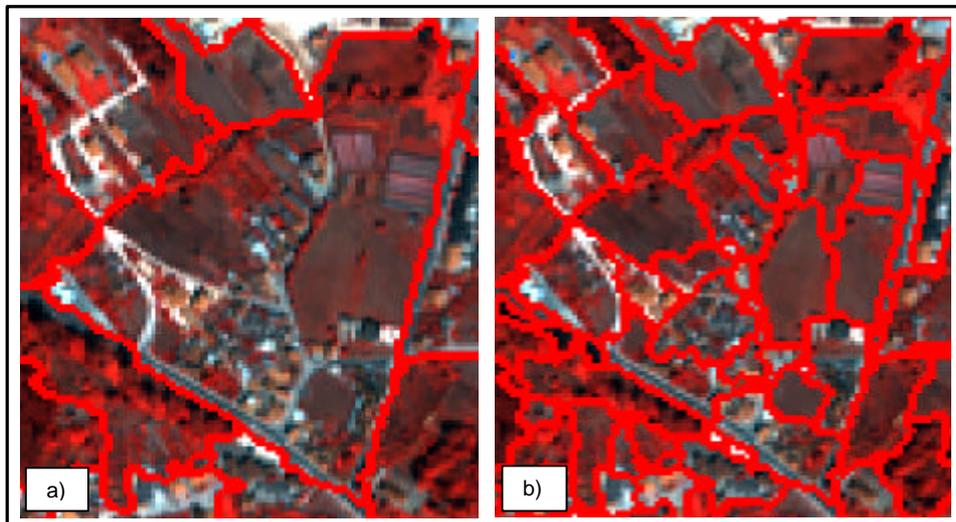


Figura 4.11 - Área da imagem IKONOS (RGB 421) relativa a uma zona com áreas agrícolas e urbanas com a sobreposição dos contornos dos objectos, gerados na segmentação, apresentados a vermelho. Fig. 4.11 a) Segmentação do nível 3 que apresenta um objecto que contém Áreas de ocupação agrícola e Áreas artificiais; Fig. 4.11 b) Segmentação do nível 2 em que os objectos formados já permitem individualizar as Áreas de ocupação agrícola.

Apesar do sucesso geral no ajustamento dos objectos à estrutura da paisagem, também ocorreram situações em que os objectos gerados não se encontram bem ajustados à forma dos objectos reais, nomeadamente em situações de pouco contraste, como por exemplo, rede viária, conforme ilustra a figura 4.12.



Figura 4.12 - Extracto da imagem IKONOS (RGB 321) com sobreposição de objectos imagem, gerados com a segmentação, apresentados a vermelho, mal ajustados aos objectos reais.

4.7.3. Desenvolvimento de bases de conhecimento

A base de conhecimento a partir da qual é efectuada a classificação foi estruturada sob a forma de uma hierarquia de classes. A hierarquia de classes foi construída tendo como objectivo classificar a cobertura do solo com base na nomenclatura de referência apresentada no quadro 4.9.

Conforme referido no capítulo 3, a cada objecto fica associado um conjunto de atributos, nomeadamente: informação espectral, forma, textura, relações de vizinhança e hierarquia (ver quadro 3.1, figura 3.4 e anexo 2). É com base nos valores dos vários atributos que é escolhido o espaço de características, para aplicar o classificador do vizinho mais próximo e que são construídas as regras utilizando funções *fuzzy* de pertença que ‘descrevem’ as propriedades das classes.

Antes de proceder à construção da hierarquia de classes, foi analisada a informação que era possível extrair de cada uma das imagens e os valores dos respectivos atributos acima referidos. Esta primeira análise é extremamente importante para definir as regras que irão ser construídas e identificar a melhor técnica para extrair a informação.

Após efectuada esta análise foram construídas quatro bases de conhecimento. A cada base de conhecimento foi atribuída uma segmentação da imagem. A hierarquia de classes, assim desenvolvida, assenta numa hierarquia de objectos, em que cada objecto conhece o seu contexto e os seus objectos vizinhos em termos horizontais e verticais. Cada base de conhecimento vai ser usada para classificar directamente a imagem segmentada que lhe está associada.

Seguidamente será descrita a construção de cada uma das bases de conhecimento e referidos, de forma mais detalhada, os objectivos que lhe estiveram subjacentes.

A base de conhecimento à qual está associada a segmentação da imagem constituída por objectos maiores (área mínima=4256 m²), registada no nível 4, será referida no texto por desenvolvimento hierárquico 4. A construção deste desenvolvimento hierárquico teve como objectivo, conforme acima referido, extrair objectos imagem cuja forma se mantinha inalterável para determinadas variações de escala como, por exemplo, algumas Infra-estruturas desportivas (142) (figura 4.8), e que eram difíceis ou impossíveis de extrair a partir da imagem segmentada directamente ligada à escala de interesse. A característica espacial que alguns objectos apresentam, i.e., manterem a forma inalterável para determinadas variações de escala, foi utilizada como critério para a sua extracção. A extracção desta informação, logo a partir da imagem segmentada constituída por objectos maiores, torna-se mais simples pois há menos confusão espectral. O procedimento na construção deste desenvolvimento hierárquico consistiu em criar, primeiro, apenas duas

sub-classes denominadas de *Rural(4)* e *Urbano(4)*, que serviram para separar as áreas com cobertura urbana das áreas com cobertura predominantemente rural. Na figura 4.13 é apresentado, como exemplo, o resultado da classificação obtida nesta fase.

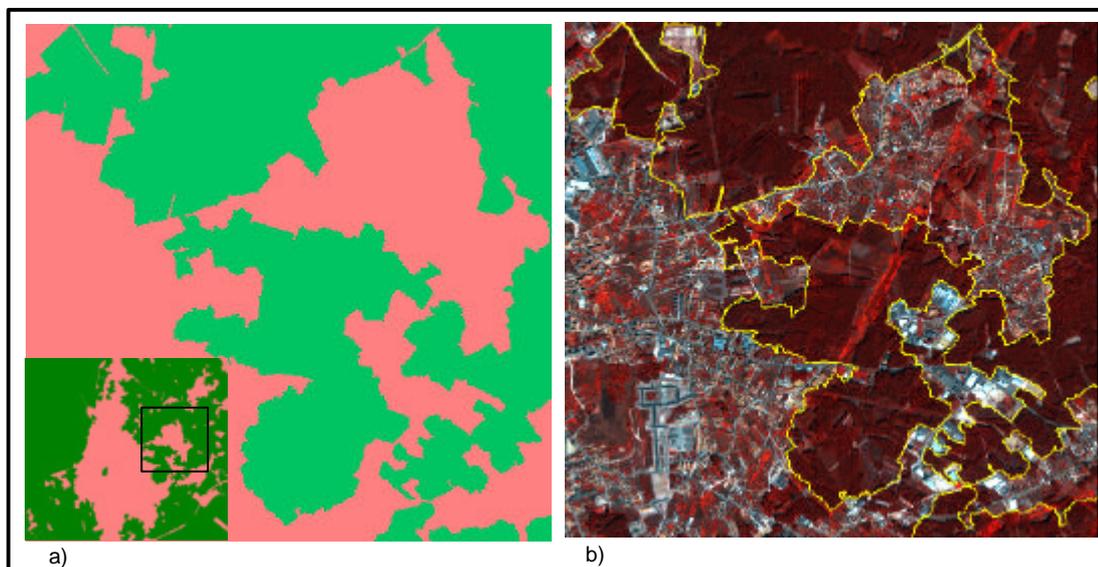


Figura 4.13 - Classificação da imagem segmentada e registada no nível 4. Fig. 4.13 a) Extracto com classificação obtida com o desenvolvimento hierárquico 4 em que a classe *Rural(4)* está representada a verde e a classe *Urbano(4)* a rosa. A localização do extracto apresentado, relativamente à área total da imagem classificada, está assinalada no canto inferior esquerdo do mapa, por um quadrado preto. Fig. 4.13 b) Imagem IKONOS (RGB 421) relativa à mesma área com a sobreposição dos polígonos extraídos correspondentes à classificação efectuada.

As classes *Rural(4)* e *Urbano(4)* funcionaram como máscaras a partir das quais se procedeu à análise separadamente. Sobre os objectos da imagem correspondentes a cada uma destas classes prosseguiu a classificação em sub-classes, que correspondiam a classes do nível três da nomenclatura de referência (quadro 4.9). Desta forma, foi possível extrair, da área inicialmente classificada como *Urbano(4)*, por exemplo, os objectos que correspondiam a zonas de lixeira, algumas áreas industriais, saibreira, áreas desportivas correspondentes a campos não relvados, áreas de corte de floresta, cemitérios e as áreas de solo nu que correspondiam às obras da Auto-estrada A8, mantendo a remanescente área a denominação *5Urbano(4)*. De referir que as áreas que apresentavam uma cobertura de solo nu como, por exemplo, as áreas de corte de floresta, estaleiros, saibreira e campos de jogos não relvados, foram inicialmente classificadas como *Urbano*.

As técnicas utilizadas no processo de classificação foram: formulação de conhecimento, ou regras, utilizando funções *fuzzy* de pertença e técnica de máscaras.

A título de exemplo, para extrair os equipamentos desportivos foram construídas três regras *fuzzy*, com base nos dados espectrais (média dos valores espectrais de cada objecto

na banda do vermelho), da forma (direcção principal) e relações de vizinhança (diferença da média entre os objectos vizinhos da banda do vermelho) combinadas com o operador lógico 'ou' (figura 4.14).

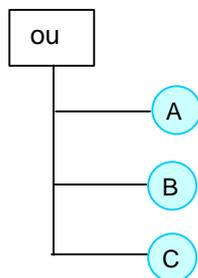


Figura 4.14 - Regras *fuzzy* conjugadas através do operador lógico 'ou', que permitiram extrair os equipamentos desportivos no desenvolvimento hierárquico 4. Para que os objectos sejam classificados como equipamentos desportivos têm de ser cumpridas a expressão A (direcção principal) ou B (diferença da média entre os objectos vizinhos na banda do vermelho) ou C (média dos valores espectrais de cada objecto na banda do vermelho).

Na figura 4.15 é apresentada a hierarquia de classes desenvolvida.

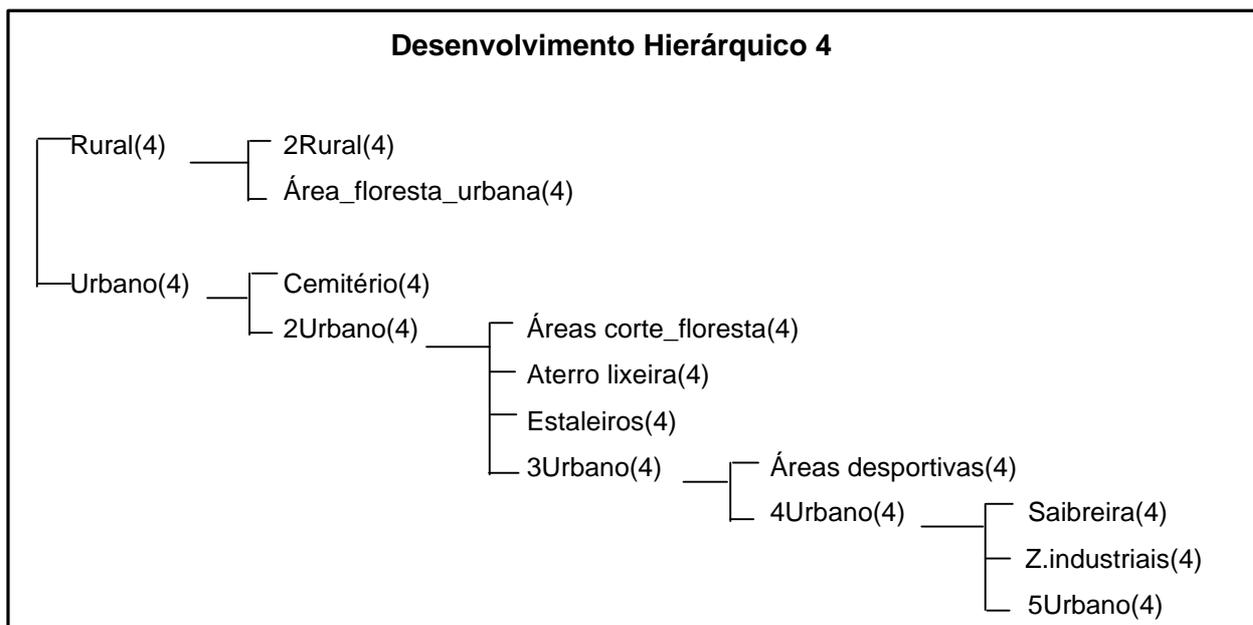


Figura 4.15 - Desenvolvimento hierárquico 4.

Ao nome das sub-classes que constituem o desenvolvimento hierárquico 4 acresce o correspondente número 4, (e.g., *Urbano(4)*). Este procedimento foi adoptado nos desenvolvimentos hierárquicos 4, 3 e 1, para facilitar a posterior combinação da informação extraída a partir dos mesmos. Pelo mesmo motivo, ou sempre que foi utilizada a técnica de máscaras (para restringir o processo de classificação aos objectos que a constituem), o nome da sub-classe é antecedido de um número (e.g., *2Urbano(4)*).

Na construção do desenvolvimento hierárquico 3, um dos objectivos foi o de

melhorar a classificação efectuada com o desenvolvimento hierárquico 4, nomeadamente as classes *Aterro lixeira(4)* e *Saibreira(4)*. Na imagem segmentada, associada ao desenvolvimento hierárquico 4, a saibreira, por exemplo, embora seja apenas representada por um objecto imagem, este não está perfeitamente ajustado à sua estrutura real. Inclui também algum coberto florestal pouco denso com pequenas áreas de corte de floresta devido às obras da A8, conforme ilustra a figura 4.16 (imagens a) e b)). Como a imagem segmentada associada ao desenvolvimento hierárquico 3 é constituída por objectos mais pequenos, foi possível refinar a classificação e extrair a informação cujo uso do solo não era saibreira (imagens c) e d) da figura 4.16).

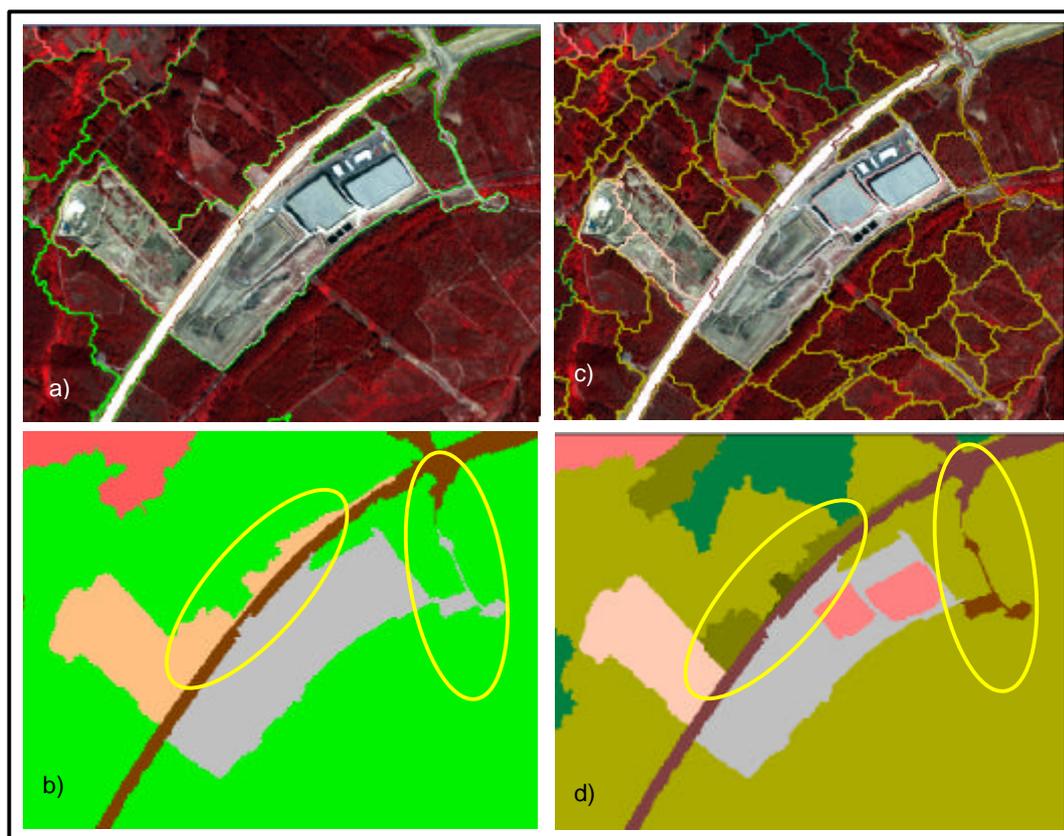


Figura 4.16 - Melhoria da extracção da informação correspondente às classes Aterro lixeira e Saibreira obtida com o desenvolvimento hierárquico 3. Fig. 4.16 a) Imagem IKONOS (RGB 421) com a sobreposição dos contornos dos objectos classificados no desenvolvimento hierárquico 4, relativos às classes Saibreira e Aterro lixeira. Fig. 4.16 b) Classificação efectuada com desenvolvimento hierárquico 4, em que a classe Saibreira está representada com cor laranja e a classe Aterro lixeira com cor cinzenta. As Fig. 4.16 c) e Fig. 4.16 d) apresentam os contornos e a classificação obtidos para as referidas classes a partir do desenvolvimento hierárquico 3.

Outro objectivo consistiu em extrair a informação correspondente às classes Folhosas, Resinosas, Povoamento florestal misto e Vegetação arbustiva e herbácea. Esta opção deve-se ao facto de não ter sido possível extrair esta informação a partir da imagem segmentada e registada no nível 2.

Na construção do desenvolvimento hierárquico 3, foram primeiro criadas as classes *Aterro lixeira(3)*, *Saibreira(3)*, *Rural(3)* e *Urbano(3)*, tendo estas herdado as propriedades das suas supra-classes relacionadas, pertencentes ao desenvolvimento hierárquico 4. A partir destas foram criadas sub-classes para extrair e melhorar a classificação anteriormente efectuada. A figura 4.17 representa a hierarquia de classes desenvolvida.

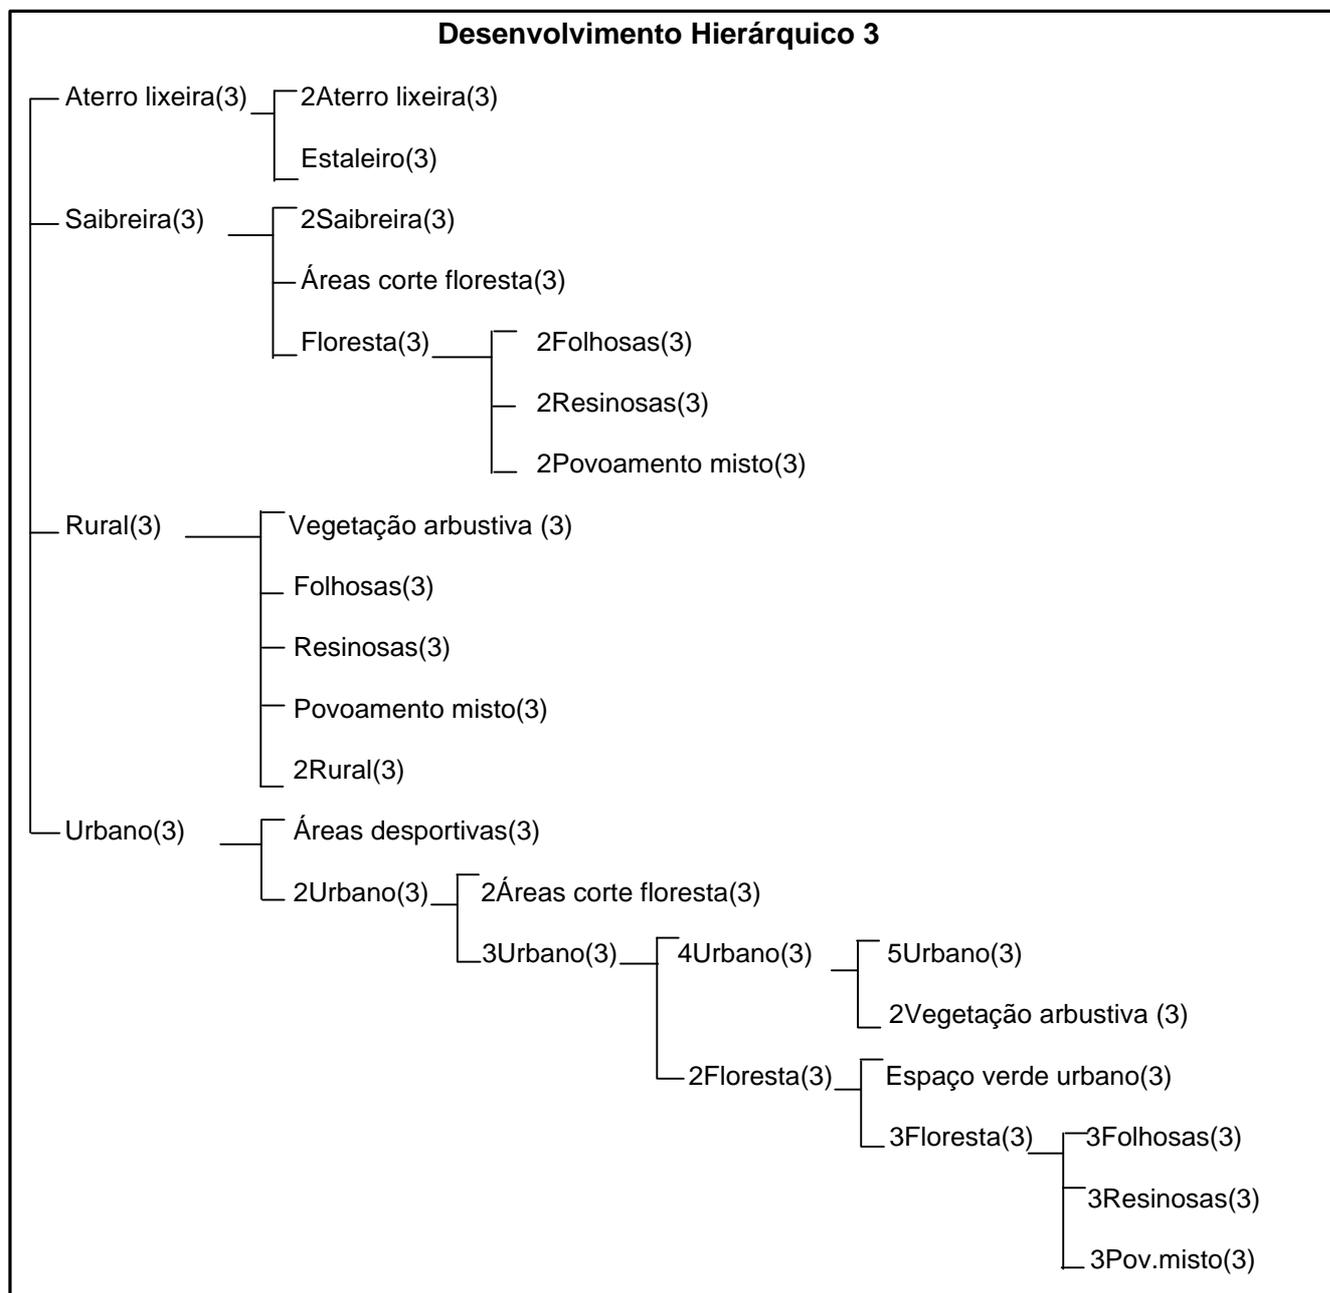


Figura 4.17 - Desenvolvimento hierárquico 3

Para extrair a informação relativamente às classes Folhosas, Resinosas, Povoamento misto e Vegetação arbustiva e herbácea foi necessário utilizar o classificador do vizinho mais próximo, tendo sido para tal escolhidas áreas de treino e o espaço

característico. Para a escolha do espaço característico recorreu-se à análise de histogramas, tendo-se concluído que o que permitia uma melhor separação das referidas classes era a banda do infravermelho próximo e a textura. A informação da textura é calculada, no método de análise orientada por objectos, com base na informação dos sub-objectos (valores espectrais e forma). Neste estudo, a informação da textura foi realizada com base na informação espectral dos sub-objectos com área mínima idêntica à do *pixel* (i.e., desvio padrão da média dos valores espectrais na banda do infravermelho próximo dos sub-objectos correspondentes a cada objecto, e média da diferença entre sub-objectos vizinhos, correspondentes a cada objecto, na banda do infravermelho próximo).

Utilizando relações de vizinhança, foi possível separar as áreas verdes urbanas. As imagens apresentadas na figura 4.18 ilustram um objecto inicialmente classificado com um grau de pertença de 100% como floresta (*2Floresta(3)*) que, ao utilizar as relações de vizinhança, foi possível classificar como área verde urbana (80% do limite de objectos classificados como *2Floresta(3)* é comum a objectos classificados como *5Urbano(3)*).

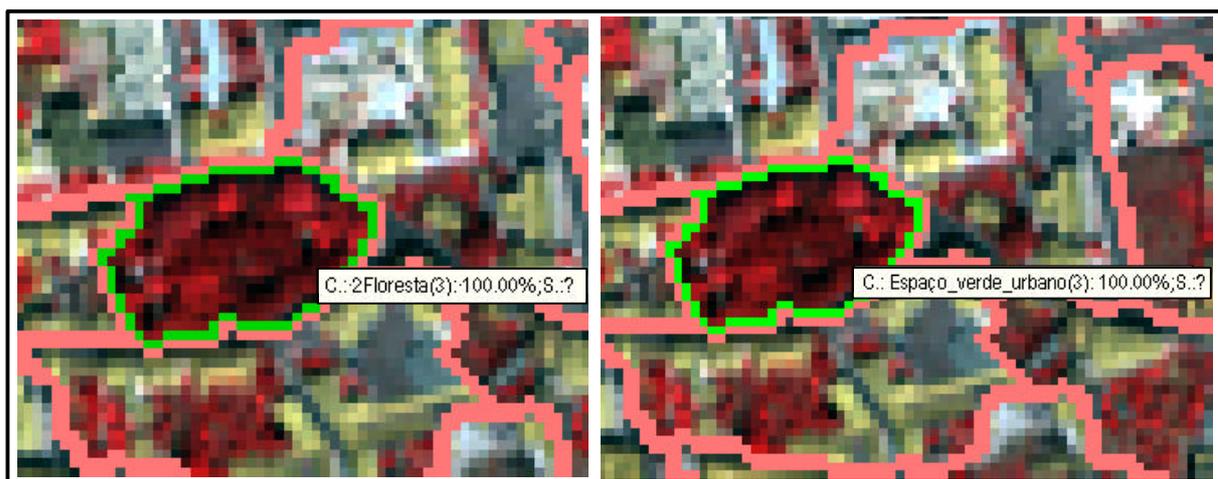


Figura 4.18 - Extracto da Imagem IKONOS com a sobreposição de informação da classe Espaço verde urbano (RGB 421). Fig. 4.18 a) Objecto classificado como floresta '*2Floresta(3)*' (cor verde) com um grau de pertença de 100%, rodeado de objectos classificados como área artificial '*5Urbano(3)*' (cor rosa). Fig. 4.18 b) Apresenta o mesmo objecto que, após aplicação de relações de vizinhança, ficou classificado como Espaço verde urbano '*Espaço_Verde_Urbano(3)*' com um grau de pertença de 100%.

Na construção do desenvolvimento hierárquico 2 criaram-se, primeiro, dez sub-classes, conforme ilustrado na figura 4.19, cuja denominação é idêntica à da nomenclatura de referência. As sub-classes correspondentes às classes de informação Vegetação arbustiva e herbácea, Estaleiros, Saibreiras, Zonas de lixeira, Serviços de utilidade pública, Infraestruturas desportivas e Zonas industriais herdaram as suas propriedades das supra-classes pertencentes aos desenvolvimentos hierárquicos superiores 3 e 4.

Para extrair a informação relativa às classes Áreas artificiais, Áreas com ocupação agrícola e Floresta, foram definidas as áreas de treino e escolhido o espaço característico, tendo-se utilizado o classificador do vizinho mais próximo combinado, através de operadores lógicos, com funções de pertença. A combinação com funções de pertença foi importante, pois permitiu construir regras como, por exemplo, *'não serem classificadas como Áreas artificiais objectos que, nos desenvolvimentos superiores, tivessem sido classificados como Floresta ou Corte de floresta'*. Isto permitiu que áreas com ocupação de pinhal e eucaliptal nascedio, que se confundem com áreas urbanas, não fossem erradamente classificadas. Desta forma, a informação das classes dos desenvolvimentos superiores puderam ser utilizadas como contexto.

As sub-classes Folhosas e Resinosas, da classe paterna Floresta, herdaram as suas propriedades das suas supra-classes relacionadas. Desta forma, objectos classificados como Floresta e cujos supra-objectos tivessem sido classificados, por exemplo, como Folhosas, no desenvolvimento superior, eram classificados como Folhosas.

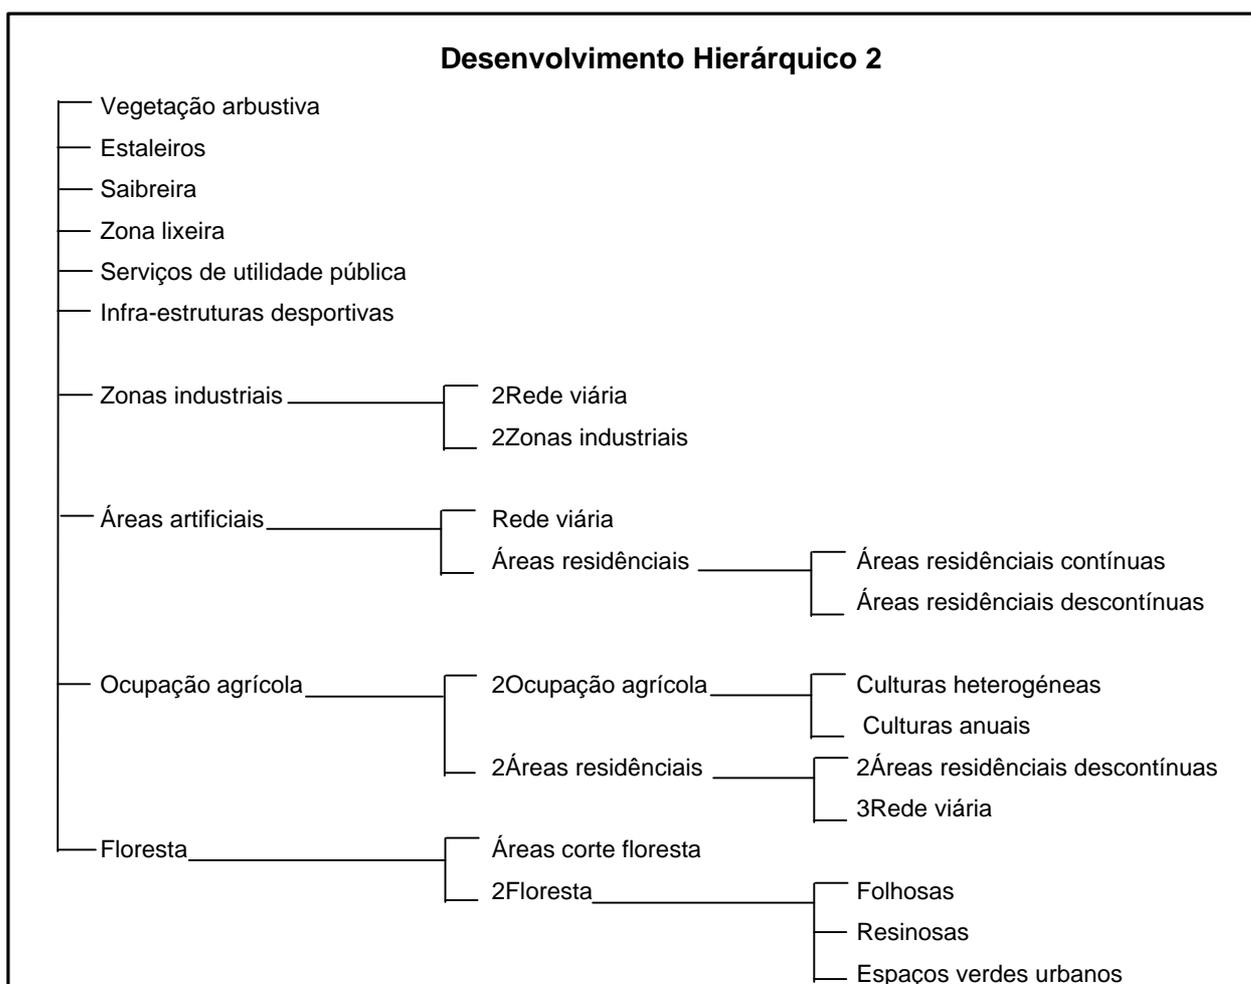


Figura 4.19 - Desenvolvimento hierárquico 2

Para discriminar as Áreas residênciais contínuas e descontínuas foi utilizada também informação contextual, nomeadamente relações com os sub-objectos. Os objectos que possuíssem uma área superior a 80% de sub-objectos classificados como Edificado eram classificados como Áreas residênciais contínuas. Os objectos imagem que possuíssem uma área entre 80% e 25% de sub-objectos classificados como Edificado eram classificados como Áreas residênciais descontínuas. Este procedimento foi também aplicado para extrair, das áreas classificadas como Áreas com ocupação agrícola, áreas que cumprissem o critério definido para discriminar as Áreas residênciais descontínuas.

A construção do desenvolvimento hierárquico 1 serviu unicamente para classificar diferentes tipos de cobertura de edifícios. A classificação obtida foi utilizada como informação de contexto, no desenvolvimento hierárquico 2, para separar, das Áreas artificiais classificadas, as Áreas residenciais e estas em Áreas residenciais contínuas e descontínuas conforme acima referido.

Na figura 4.20 é apresentada a hierarquia de classes desenvolvida.

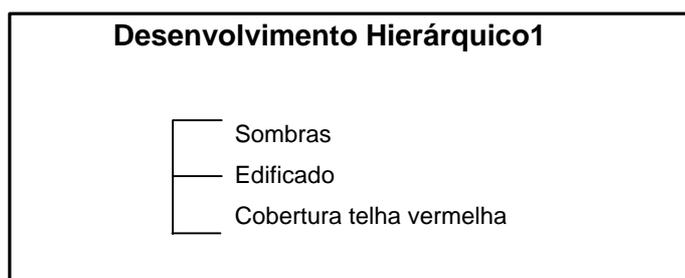


Figura 4.20 - Desenvolvimento hierárquico 1

Para extrair a informação relativa, por exemplo, à Cobertura telha vermelha foram construídas regras *fuzzy* utilizando dados espectrais (e.g., quociente entre o valor médio espectral de cada objecto na banda do vermelho e o somatório dos valores médios espectrais das quatro bandas) e informação contextual. Muitos objectos relativos a zonas de solo nu, como campos de jogos não relvados (figura 4.21 a)) e zonas de estaleiros (figura 4.21 b)) foram também identificados como Cobertura de telha vermelha. A forma de contornar este problema foi utilizar, como informação contextual, a classificação dos objectos imagem adjacentes em termos verticais classificados com o desenvolvimento hierárquico 3. As imagens c) e d) da figura 4.21 apresentam o resultado após utilização da informação de contexto. O mesmo procedimento foi utilizado na identificação da informação do Edificado. Conforme acima referido, as imagens segmentadas associadas ao desenvolvimento hierárquicos 3 e 4 são constituídas por objectos imagem maiores e cuja forma se ajusta à forma dos objectos reais, o que possibilita a sua extracção sem os

problemas de confusão espectral que ocorrem na classificação dos objectos cujo tamanho é idêntico ou próximo do *pixel*.

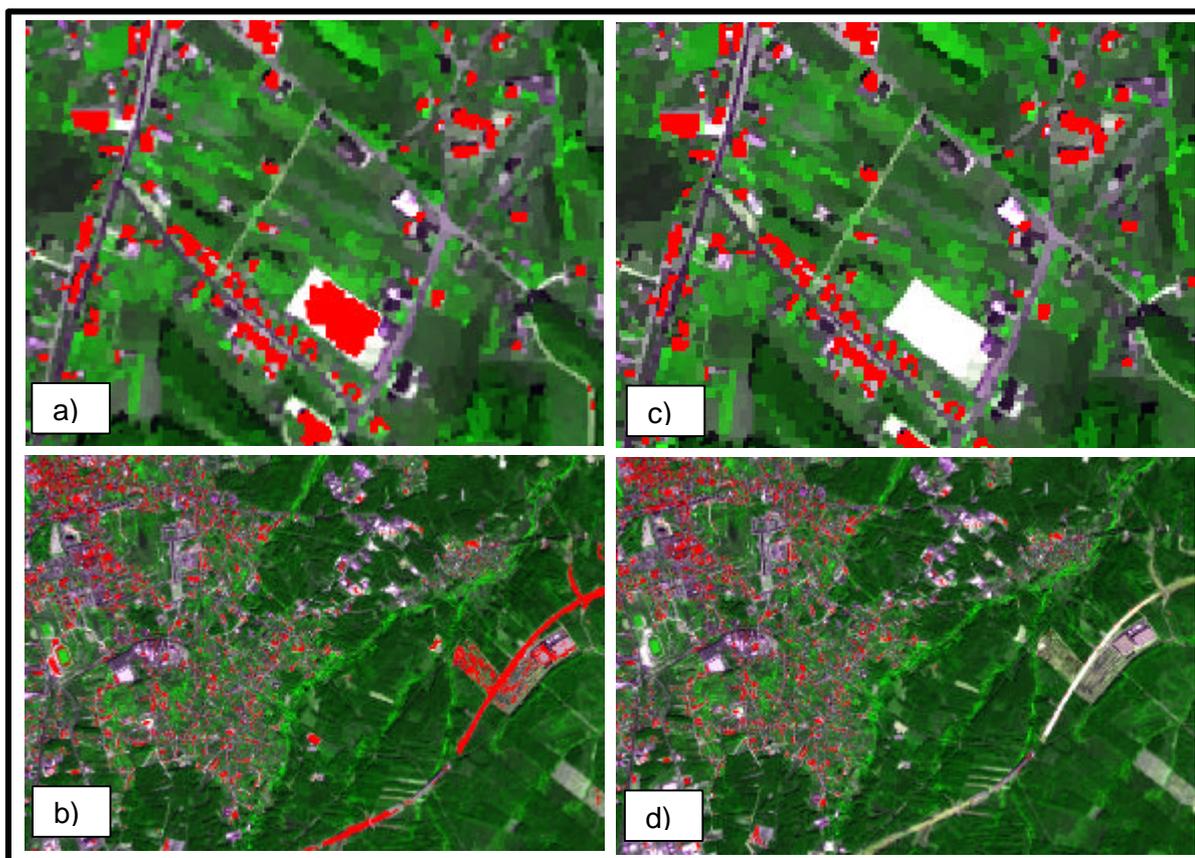


Figura 4.21 - Classificação de edifícios com cobertura de telha vermelha com e sem utilização de informação de contexto. As Fig. 4.21 a) e Fig. 4.21 b) apresentam a classificação de edifícios com cobertura de telha vermelha (cor vermelha) sem utilização de informação de contexto. As Fig. 4.21 c) e Fig.4.21 d) apresentam o resultado da classificação após utilização de informação de contexto (RGB 341).

4.7.4 Classificação

Relativamente ao processo de classificação, foi utilizado o processo iterativo tendo-se efectuado, em primeiro lugar, a classificação dos objectos imagem associados ao desenvolvimento hierárquico 4, em segundo lugar os associados ao desenvolvimento hierárquico 3, em terceiro os associados ao desenvolvimento hierárquico 1 e, por último, os objectos imagem associados ao desenvolvimento hierárquico 2. A sequência da classificação referida é apresentada no esquema da metodologia proposta (figura 3.1).

A aplicação do classificador do vizinho mais próximo foi precedida de uma análise preliminar da classificação (figura 4.22), em que os resultados obtidos foram avaliados com base nos valores do grau de pertença. Deste modo, foram identificados os objectos que

tenham sido classificados com grande ambiguidade, cujo grau de pertença era muito baixo ou não tinham sido atribuídos a nenhuma classe (implicando a definição de novas áreas de treino).

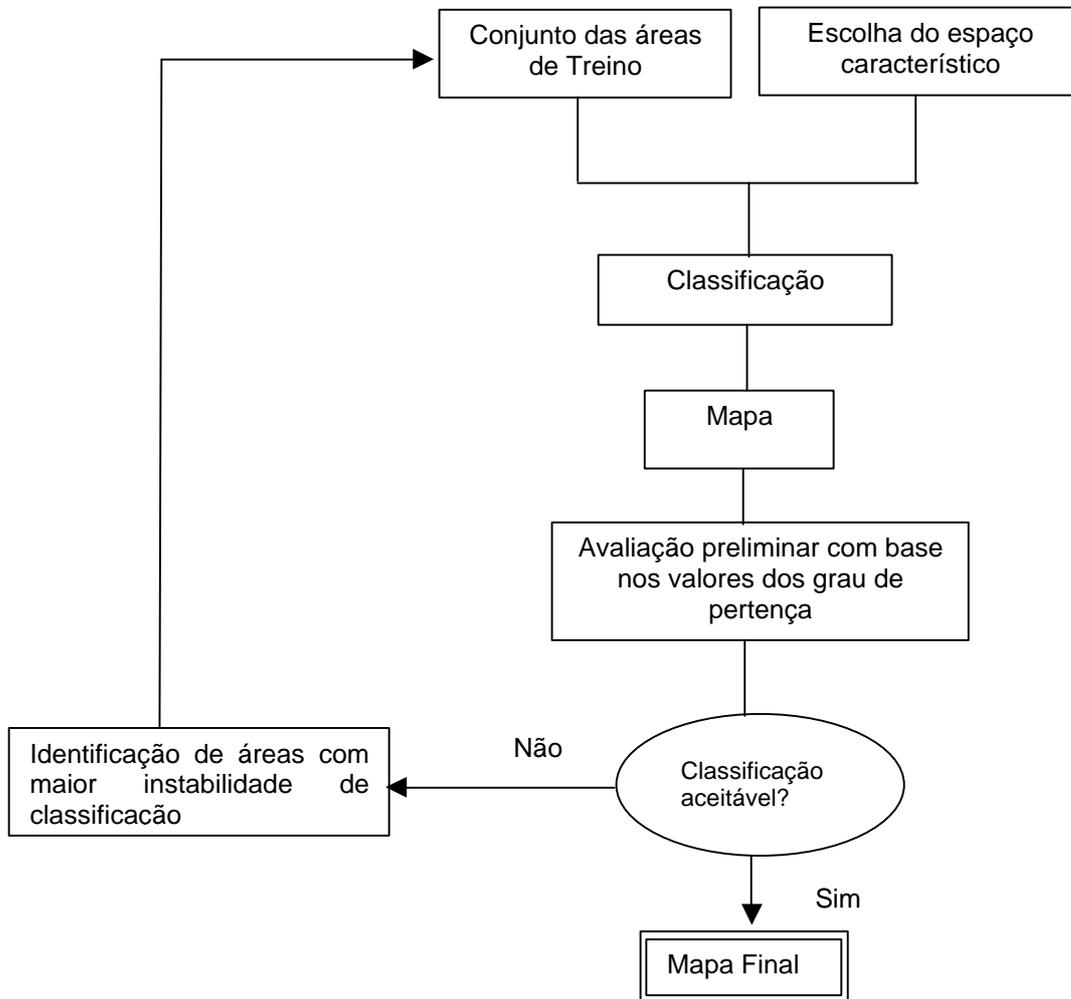


Figura 4.22 - Procedimento utilizado na classificação da imagem de satélite.

Após concluída a classificação, foram criados dois grupos semânticos (figura 4.23), Rede viária e Áreas residenciais descontínuas, para que os objectos classificados, por exemplo, como 1Rede viária, 2Rede viária, e 3Rede viária, passassem a fazer parte da mesma classe de informação.



Figura 4.23 - Grupos semânticos

O mapa de ocupação do solo produzido é apresentado no anexo 6. A nomenclatura inicialmente estabelecida e apresentada no anexo 1, é constituída por 30 classes, existindo na área de estudo apenas 22 classes (quadro 4.9), das quais foi possível identificar 16. Das 16 classes identificadas, 10 correspondem a classes urbanas. No quadro 4.12 é apresentado o número de classes existentes em cada nível de detalhe da nomenclatura estabelecida no estudo, existentes na área de estudo e identificadas na classificação.

Quadro 4.12 - Número de classes existentes em cada nível de detalhe da nomenclatura estabelecida no estudo, existentes na área de estudo e identificadas na classificação.

Nível da nomenclatura	Número de classes da nomenclatura	Número de classes da nomenclatura existentes na área de estudo	Número de classes identificadas
1	6	4	4
2	18	12	10
3	14	11	9
4	6	6	5

No quadro 4.13 são apresentadas as classes da nomenclatura e a metodologia desenvolvida com que foram identificadas.

Quadro 4.13 - Identificação das classes da Nomenclatura de Referência existentes na área de estudo e indicação da sua identificação com base na análise de imagens orientadas por objectos

Código Nomenclatura	Classes da Nomenclatura	Classes identificadas com base na análise de imagens orientada por objectos	
1111	Áreas residenciais contínuas	Sim	Classificação da imagem com base na avaliação dos sub-objectos. Os objectos que continham mais de 80% de sub-objectos (cuja área mínima é a do <i>pixel</i> -16 m2) classificados como Edificado foram classificados como Áreas residenciais contínuas.
1112	Áreas residenciais descontínuas	Sim	Classificação da imagem com base na avaliação dos sub-objectos. Os objectos que continham entre 50% a 80% de sub-objectos (cuja área mínima é a do <i>pixel</i> 16 m2) classificados como Edificado foram classificados como Áreas residenciais descontínuas.
112	Serviços de utilidade pública e administração local	Sim	Apenas foi possível identificar os cemitérios. Os restantes serviços foram classificados como Áreas residenciais contínuas e descontínuas. Para classificar os objectos, foram utilizados os atributos da forma:(1) direcção principal dos objectos, (2) característica linear baseada nos sub-objectos (comprimento).
1211	Zonas industriais	Sim	Apenas foi possível identificar as grandes áreas industriais. As pequenas indústrias inseridas no meio predominantemente residencial, e cuja função é impossível de classificar a partir da cobertura (semelhante aos edifícios habitacionais), foram classificadas como Áreas residenciais contínuas e descontínuas. Foi utilizado o atributo da textura baseada nos valores espectrais dos sub-objectos (média de SO: desvio padrão na banda do azul) e atributos espectrais: (1) brilho, (2) desvio padrão na banda do azul.
1212	Zonas comerciais e financeiras	Não	Impossível de discriminar apenas com base em dados espectrais. Classificados como Áreas residenciais contínuas e descontínuas.
1221	Rede viária	Sim	Algumas estruturas viárias foram identificadas a partir dos atributos da forma dos objectos e as restantes foram classificadas como Áreas residenciais, Agrícolas e Florestais. Os atributos da forma utilizados foram: (1)comprimento/largura, (2) Índice da forma.
1222	Rede ferroviária	Não	Impossível de discriminar apenas com base em dados imagem com 4m de resolução espacial. Incluída nas restantes classes.
131	Saibreira	Sim	Identificada a partir dos atributos espectrais (quociente entre o valor médio espectral de cada objecto na banda do azul e o somatório dos valores médios espectrais de todas as bandas).
132	Zonas de lixeira e depósitos sucata	Sim	Identificadas utilizando informação da textura baseada na forma dos sub-objectos (densidade de SO: desvio padrão).
133	Estaleiros	Sim	Identificados utilizando atributos espectrais e da forma: (1) quociente entre o valor médio espectral de cada objecto na banda do azul e o somatório dos valores médios espectrais de todas as bandas, (2) densidade.
134	Etar	Não	Foi impossível de discriminar. Classificadas como Áreas residenciais.
141	Espaços verdes urbanos	Sim	Identificados com base nas relações entre objectos vizinhos (limites relativos entre as classes Áreas residenciais contínuas e descontínuas).
142	Infra-estruturas desportivas	Sim	Apenas foi possível identificar os grandes campos. As restantes infra-estruturas foram classificadas como Áreas residenciais contínuas e descontínuas. Foram utilizados atributos da forma (direcção principal) e atributos espectrais: (1) média dos valores espectrais na banda do vermelho, (2) diferença média entre objectos vizinhos na banda do vermelho.
143	Zonas históricas e espaços culturais	Não	Impossível de discriminar. Classificadas como Áreas residenciais.

21	Áreas agrícolas com culturas anuais	Sim	Classificação da imagem, utilizando o classificador do vizinho mais próximo, no seguinte espaço característico: média, quociente e brilho obtidos a partir dos valores espectrais dos <i>pixels</i> que constituem os objectos, tendo sido utilizadas as quatro bandas multiespectrais.
22	Culturas permanentes	Não	Poucas áreas e muito pequenas, difíceis de identificar com base nos dados espectrais. Classificadas como culturas anuais associadas a Culturas permanentes.
24	Zonas agrícolas heterogéneas	Sim	Classificação da imagem, utilizando o classificador do vizinho mais próximo, no seguinte espaço característico: média, quociente e brilho obtidos a partir dos valores espectrais dos <i>pixels</i> que constituem os objectos, tendo sido utilizadas as quatro bandas multiespectrais.
31	Folhosas	Sim	Classificação da imagem, utilizando o classificador do vizinho mais próximo, no seguinte espaço característico: média obtida a partir dos valores espectrais dos <i>pixels</i> , que constituem os objectos, na banda multiespectral do infravermelho próximo; textura baseada nos valores espectrais dos correspondentes sub-objectos: (1) diferença média entre objectos vizinhos na banda do infravermelho próximo. (2) média de SO:desvio padrão na banda do infravermelho próximo.
32	Resinosas	Sim	Classificação da imagem, utilizando o classificador do vizinho mais próximo, no seguinte espaço característico: média obtida a partir dos valores espectrais dos <i>pixels</i> , que constituem os objectos, tendo sido utilizadas a banda multiespectral do infravermelho próximo; textura baseada nos valores espectrais dos correspondentes sub-objectos: (1) diferença média entre objectos vizinhos na banda do infravermelho próximo. (2) média de SO:desvio padrão na banda do infravermelho próximo.
33	Povoamento florestal misto	Não	Impossível de discriminar. Classificados como Folhosas ou Resinosas
41	Vegetação arbustiva e herbácea	Sim	Classificação da imagem, utilizando o classificador do vizinho mais próximo, no seguinte espaço característico: média obtida a partir dos valores espectrais dos <i>pixels</i> , que constituem os objectos, tendo sido utilizadas as bandas do vermelho e infravermelho próximo; textura baseada nos valores espectrais dos correspondentes sub-objectos, tendo sido usada: (1) a diferença média entre objectos vizinhos na banda do vermelho e infravermelho próximo e (2) média de SO:desvio padrão na banda do vermelho e infravermelho próximo.
43	Áreas corte floresta		Classificação da imagem, utilizando: o atributo espectral brilho (calculado a partir das quatro bandas da imagem); relações entre objectos vizinhos (limites relativos entre objectos classificados como floresta) e o classificador do vizinho mais próximo, no seguinte espaço característico: (1) média obtida a partir dos valores espectrais dos <i>pixels</i> , que constituem os objectos, tendo sido utilizadas as bandas do vermelho, verde, azul, infravermelho próximo e (2) características lineares baseadas nos sub-objectos (comprimento, comprimento/largura).

4.8 Avaliação da qualidade do mapa de ocupação do solo produzido

Para a avaliação da precisão do mapa de ocupação do solo, produzido para a área de estudo, foi gerada uma matriz de erro. Esta foi construída à custa da verificação da classificação da ocupação do solo, em pontos seleccionados sobre o mapa temático, pelo método de amostragem aleatória (anexo 7). Os índices usados para avaliar a precisão foram a precisão global e o Índice *Kappa*. Os índices calculados para avaliar a precisão com que foi identificada cada classe foram a precisão do produtor e a precisão do utilizador. A dimensão da amostra foi constituída por 750 pontos, tendo sido utilizada como unidade da amostra o objecto. Para a verificação da ocupação do solo, nesses pontos, foi utilizada a fusão dos dados imagens do satélite IKONOS e dados recolhidos no terreno. A matriz de confusão e os índices de precisão do mapa de ocupação do solo obtidos são apresentados no quadro 4.14. No mapa produzido foram identificadas 16 classes. A precisão global obtida foi de 83%.

Quadro 4.14 - Matriz de confusão e índices de precisão para o mapa de ocupação do solo produzido

		Referência														Total <i>pixels</i>	Precisão do utilizador (%)		
		1111	1112	112	1211	1221	131	132	133	141	142	21	24	31	32			41	43
C L A S S I F I C A Ç Ã O	1111	9	5		3										2		19	47	
	1112	2	36		1	2					1				1	2		45	80
	112			0														0	0
	1211				13													13	100
	1221		6			3												9	33
	131						1							1				2	50
	132							2										2	100
	133								1								1	2	50
	141									1								1	100
	142										2							2	100
	21											14	7	1	1	4		27	52
	24												10		1			11	91
	31		2									1		110	55	2		170	65
	32		1									1		16	413	3		434	95
	41											1				7		8	88
	43													2			10	12	83
Total <i>pixels</i>	11	45		17	5	1	2	1	1	2	18	17	130	471	20	11	757		
Precisão do produtor(%)	88	72	0	76	60	100	100	100	100	100	78	59	85	88	35	91			

Precisão Global	0.83
Kappa	0.74

No quadro 4.14 estão apresentadas todas as classes da nomenclatura de referência identificadas. Efectuando uma análise aos valores da matriz de erro construída e aos índices de precisão obtidos, conclui-se que:

- a) a precisão das diversas classes cartografadas nos mapas difere significativamente de classe para classe, existindo classes classificadas com elevada precisão, tais como as 141 (Espaços verdes urbanos), 142 (Infra-estruturas desportivas), 1211 (Zonas industriais), 32 (Resinosas) e 43 (Áreas corte floresta), e outras com baixa precisão, como seja a 1221 (Rede viária).
- a) existem classes que apresentam precisões do utilizador e produtor iguais e com um valor de 100%, como sejam as classes 141 (Espaços verdes urbanos) e 142 (Infra_estruturas desportivas) o que indica que estas classes foram correctamente identificadas. Contudo, classes como a 1111 (Áreas residenciais contínuas), 1221 (Rede viária) e 41 (Zonas com vegetação arbustiva e herbácea) apresentam valores muito diferentes.
- b) devido a ter sido utilizada uma amostra aleatória, as classes 112 (Serviços de utilidade pública e administração local), 131 (Saibreiras), 132 (Zonas de lixeira), 133 (Estaleiros), 141 (Espaços verdes urbanos) e 142 (Infra-estruturas desportivas) não possuem um número significativo de pontos de validação, não contribuindo por isso significativamente para os índices de precisão. Contudo, com base no conhecimento da área, conclui-se que estas são algumas das classes melhor identificadas nos mapas e para as quais a ambiguidade na classificação foi menor. Uma análise da ambiguidade, ou incerteza, da classificação é apresentada na secção 4.9.
- b) fazendo uma análise comparativa entre os valores da precisão global, obtidos para as classes artificiais e não artificiais, verifica-se que a precisão é ligeiramente inferior para as Áreas artificiais (80%). Contudo, este resultado deve-se à distribuição do número de pontos de validação conforme acima referido.

Da análise mais detalhada sobre a precisão das várias classes pode concluir-se que:

- a) relativamente à identificação das classes residenciais, até ao nível IV da nomenclatura, a classe 1111 (Áreas residenciais contínuas) apresentou uma precisão do produtor (88%) superior à do utilizador (47%). A razão do baixo valor para a precisão do utilizador deve-se à classificação como 1111 de zonas que pertenciam efectivamente a outra classe, nomeadamente às classes 1112 (Áreas residenciais descontínuas), 1211 (Zonas industriais) e 41 (Zonas com vegetação arbustiva e herbácea). A classe 1112 (Áreas residenciais descontínuas)

apresenta um valor de 80% para a precisão do utilizador e 72% para a precisão do produtor o que é um resultado bastante bom.

- b) a classe 1211 (Zonas industriais) apresenta, para a precisão do utilizador, um valor de 100%, o que é bastante elevado, embora a precisão do produtor seja de 76%, o que revela a existência de erros de omissão. Este resultado é compreensível dado que, na área de estudo, existem unidades industriais inseridas na zona urbana com cobertura idêntica, o que é impossível de discriminar automaticamente.
- c) a classe 41 (Zonas com vegetação arbustiva e herbácea) possui um valor elevado para a precisão do utilizador (88%) apresentando apenas erros de comissão com a classe 21 (Áreas agrícolas com culturas anuais) o que significa que o que foi classificado está correctamente classificado, mas, em contrapartida, o valor para a precisão do produtor é o mais baixo da classificação (erros de omissão elevados);
- d) para a classe 31 (Folhosas) verifica-se que, embora a precisão do produtor seja de 85%, a precisão do utilizador é de 65%, tendo sido classificadas como pertencendo à classe 31 zonas que pertenciam à classe 32 (Resinosas).
- e) as classes 32 (Resinosas) e 43 (Áreas corte floresta) apresentam valores elevados, quer para a precisão do produtor quer para a precisão do utilizador.

Ao avaliar a capacidade do método utilizado em discriminar as classes de informação da nomenclatura de referência conclui-se que:

- a) o facto de se ter optado por extrair, a partir das imagens segmentadas constituídas por objectos maiores, informação que pudesse servir como contexto para classificar a imagem segmentada relacionada com a escala de interesse, revelou-se uma correcta opção. Por exemplo, na imagem segmentada directamente relacionada com a escala de interesse, os objectos gerados correspondentes às áreas com plantação recente de pinhal, apresentavam características espectrais semelhantes com outras classes de informação, nomeadamente Zonas com vegetação arbustiva e herbácea, o que foi contornado com a utilização de informação contextual. Este procedimento foi também utilizado para atenuar a confusão espectral entre áreas que possuem solo nu (e.g., Saibreiras, Zonas de lixeira, Estaleiros, Grandes campos não relvados) e o Edificado nomeadamente edifícios com coberturas de telha vermelha, acima referidos e ilustrados na figura 4.21.
- b) o método utilizado para discriminar as Áreas residenciais contínuas das Áreas

residenciais descontínuas, com base na percentagem de ocupação dos sub-objects, embora tenha permitido discriminar bastante bem as áreas urbanas residenciais, é dependente da correcta classificação dos sub-objects. As regras utilizadas são muito semelhantes às utilizadas na interpretação visual das imagens.

- c) classes de informação que são impossíveis de classificar apenas com informação espectral ao nível do *pixel* foram aqui correctamente identificadas devido à abordagem baseada em objects, e.g., as classes 141 (Espaços verdes urbanos) e 142 (Infra-estruturas desportivas). Para a classificação da classe 141 foram apenas utilizadas as relações de vizinhança e para a classificação da classe 142 foi utilizada informação espectral da forma e relações de vizinhança.
- d) uma das componentes que caracteriza o Concelho é a sua dinâmica industrial, e a área de estudo abrange duas áreas industriais que foram efectivamente bem identificadas pelo método utilizado (a extracção da informação foi efectuada com base na informação espectral e textura). Contudo, como não foi possível extrair com sucesso os contornos das construções, que não apresentavam um bom contraste relativamente ao pavimento circundante, optou-se por classificar apenas a mancha de ocupação industrial, conforme apresenta a figura 4.24.

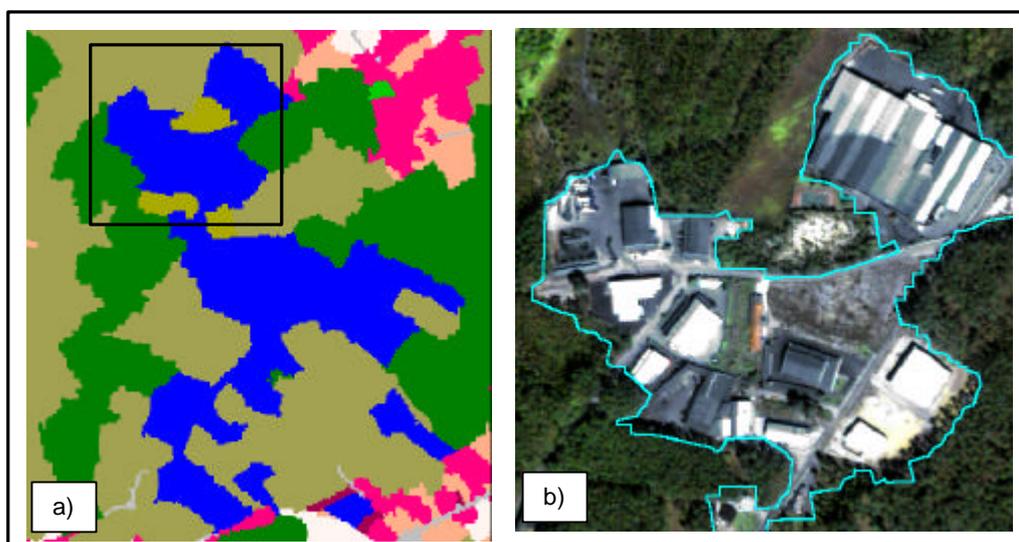


Figura 4.24 – Identificação de áreas industriais. Fig. 4.24 a) extracto com a classificação da imagem IKONOS em que a cor azul representa uma Zona industrial. Fig. 4.24 b) ampliação correspondente ao quadrado preto indicado na Fig. 4.24.

Os problemas ocorreram essencialmente com:

- (a) as classes de uso do solo que tinham uma estrutura e uma cobertura do solo semelhante mas diferiam nas suas características funcionais, como sejam as

classes 1212 (Zonas comerciais e financeiras), 112 (Serviços de utilidade pública e administração local), 134 (Etar) e 143 (Zonas históricas e espaços culturais). De referir ainda que, na área de estudo, as estruturas correspondentes a estas classes de informação são pequenas e praticamente idênticas em termos de tamanho e forma às estruturas habitacionais, não tendo sido, por isso, possível detectar nenhuma característica específicas ao nível da forma, textura ou relações de vizinhança, que permitissem construir regras que tornassem possível a diferenciação destas classes.

- (b) as classes relativamente às quais não foi possível gerar objectos imagem bem ajustados à estrutura dos objectos reais, o que aconteceu com as classes 1221 (Rede viária) e 1222 (Rede ferroviária).

De referir que, relativamente à classe 112 (Serviços de utilidade pública e administração local), foi apenas possível extrair um serviço de utilidade pública, os cemitérios, através de relações espaciais ao nível da forma entre diferentes objectos imagem hierárquicos, correspondentes ao mesmo objecto real (objectos imagem possuindo sub-objectos com a mesma forma).

As razões que levaram a que não se conseguisse gerar segmentos imagem bem adaptados às infra-estruturas viárias são várias, destacando-se as sombras, devidas às árvores, a vegetação alta e a edifícios que se encontram ao longo destas estruturas. A classe 1222 (Rede ferroviária) é praticamente imperceptível, dada a quantidade de vegetação e arvoredo e, por outro lado, a resolução espacial de 4 m não é apropriada para permitir extrair esta classe de informação. O problema resultante das sombras não foi possível de contornar. Tentou-se isolar as zonas de sombra e, posteriormente, criar um grupo semântico com os objectos atribuídos à rede viária, mas o resultado não foi satisfatório, pois não se conseguiu extrair das zonas de sombra o que apenas correspondia à infra-estrutura viária.

Das classes não artificiais apenas não foi utilizada, no processo de classificação, a classe 22 (Culturas permanentes) (que na área de estudo têm expressão muito reduzida) em virtude de se ter verificado que a sua definição introduzia erros na representação da classe 24 (Zonas agrícolas heterogéneas), os quais resultam da sua semelhança espectral. No mapa final, as áreas com culturas permanentes aparecem incluídas nas áreas classificadas como Zonas agrícolas heterogéneas.

4.9 Análise e representação gráfica da incerteza temática

A análise da incerteza temática foi realizada com base na informação dos atributos da classificação relativamente à melhor e segunda melhor classificação. No método de classificação utilizado, os objectos são atribuídos à classe relativamente à qual o grau de pertença é maior. Contudo, um objecto classificado com um elevado valor de pertença a uma certa classe não significa necessariamente que esteja bem classificado. Se existir apenas uma pequena diferença entre o melhor e o segundo melhor valor de pertença, isto significa que o resultado da classificação é pouco claro e, conseqüentemente, existe ambigüidade ou incerteza na classificação.

Para realizar o cálculo da incerteza foi determinada, para cada classe, a distribuição da frequência dos valores da probabilidade para o melhor e o segundo melhor grau de pertença, tendo sido considerados os intervalos de probabilidade que constam dos quadros 3.2 e 4.15. Relativamente à representação gráfica da incerteza, esta foi efectuada com base nos conceitos 'grande incerteza', 'pouca incerteza' e 'média incerteza'. Para isso, foram definidos critérios em função dos intervalos considerados e que constam também dos quadros 3.2 e 4.15. Para proceder à análise e representação gráfica da incerteza foi necessário exportar para ambiente SIG a classificação efectuada da imagem. Procedendo a operações SIG de análise espacial foram identificados os objectos cujos graus de pertença às classes (valores de probabilidade) correspondiam a cada intervalo e determinada a respectiva área. Com base na informação obtida, foi construído o quadro 4.15. As operações efectuadas em ambiente SIG são referidas na secção 4.11.

O mapa final de ocupação do solo é o resultado da combinação da informação extraída em vários desenvolvimentos hierárquicos. No quadro 4.15 é apresentada a integração da distribuição dos valores da probabilidade, para a melhor e segunda melhor classificação, obtida nas várias etapas relativamente às classes que constam no mapa final. À frente do nome de cada classe é indicado um número que indica o desenvolvimento hierárquico em que foram obtidos os valores apresentados na tabela.

Seguidamente serão apresentados os resultados: (1) da distribuição da frequência dos valores da probabilidade para a melhor classificação; (2) quantificação, para cada classe, dos objectos que tiverem apenas um grau de pertença com valor '1' (total pertença) a essa classe.

. **Quadro 4.15** – Integração da distribuição da frequência dos valores da probabilidade, para a melhor e segunda melhor classificação, obtida nas várias etapas relativamente às classes que constam no mapa final

Probabilidade do melhor valor da classificação]90,100]]80,90]]70,80]						[0,70]					
	Muita Incerteza				Média Incerteza			Pouca Incert.			Muita Incerteza			Média Incert.			Pouca Incert.			Muita Incerteza		Média Incert.		Muita Incert.		Soma		
]90,100]]80,90]]70,80]]50,70]]0,50]]80,90]]70,80]]50,70]]0,50]]70,80]]50,70]]0,50]]0,70]			
	Área (ha)	%	Área (ha)	%	Área (ha)	%	Área (ha)	%	Área (ha)	%	Área (ha)	%	Área (ha)	%	Área (ha)	%	Área (ha)	%	Área (ha)	%	Área (ha)	%	Área (ha)	%	Área (ha)	%	ha	%
Áreas residenciais contínuas (II)							1.7	0.6	137.0	50.3			0.9	0.3	7.5	2.8	50.7	18.8	1.6	0.6	4.9	1.8	24.0	8.9	42.9	15.9	271.2	3.3
Áreas residenciais descontínuas (II)	0.5	0.1					6.6	1.0	279.0	44.0	0.2	0.0	6.2	1.0	53.0	8.4	118.6	18.7	75.0	11.8	28.0	4.4	34.5	5.4	32.7	5.2	634.3	7.8
Serviços de utilidade pública e ad. Local (IV)									3.9	100.0																	3.9	0.0
Zonas industriais (II)	0.4	0.3	2.2	1.9	1.3	1.1	1.8	1.5	111.0	94.3									0.5	0.4	0.5	0.4					117.7	1.4
Rede viária (II)	0.4	0.4	1.0	1.1	1.2	1.3	3.2	3.6	23.2	26.1			1.4	1.6	3.4	3.8	8.0	9.0	14.8	16.6	3.8	4.3	10.6	11.9	17.9	20.1	88.9	1.1
Saibreira (III)									10.0	100.0																	10.0	0.1
Zonas de lixeira (III)									22.0	100.0																	22.0	0.3
Estaleiros (III)									33.7	100.0																	33.7	0.4
Espaços verdes urbanos (II)	1.0	4.3	0.7	3.0			0.3	1.3	17.4	75.7	0.6	2.6	0.3	1.3					1.2	5.2	0.7	3.0			0.8	3.5	23.0	0.3
Infra-estruturas desportivas (III)									4.5	100.0																	4.5	0.1
Áreas agrícolas com culturas anuais (II)	87.0	27.4	46.6	14.7	16.0	5.0	3.7	1.2	48.0	15.1	10.6	3.3			17.3	5.4	19.6	6.2	26.5	8.3	6.6	2.1	12.1	3.8	23.7	7.5	317.7	3.9
Zonas agrícolas heterogéneas (II)	25.9	13.1	6.0	3.0	7.0	3.5	4.7	2.4	34.9	17.7	5.9	3.0	8.0	4.0	8.5	4.3	29.0	14.7	22.7	11.5	8.1	4.1	11.7	5.9	25.3	12.8	197.7	2.4
Folhosas (III)	784.0	43.8	230.0	12.9	74.4	4.2	38.9	2.2	117.1	6.5	29.8	1.7	70.4	3.9	33.7	1.9	25.3	1.4	8.5	0.5	70.2	3.9	61.6	3.4	245.7	13.7	1789.6	22.0
Resinosas(III)	3511.7	78.1	281.0	6.3	71.7	1.6			597.8	6.5	3.4	0.1	4.7	0.1	1.3	0.0	18.3	0.4	0.8	0.0	0.9	0.0			2.4	0.1	4494.0	55.1
Vegetação arbustiva e herbácea (III)									45.0	72.8													3.8	6.1	13.0	21.0	61.8	0.8
Áreas corte floresta (III)									81.9	100.0																	81.9	1.0
Total de hectares	4410.9		567.5		171.6		60.9		1566.5		50.5		91.9		124.7		269.5		151.6		123.7		158.3		404.4		8152.0	
Percentagem área %	54.1		7.0		2.1		0.7		19.2		0.6		1.1		1.5		3.3		1.9		1.5		1.9		5.0		100.0	

A quantificação, para cada classe, dos valores relativos ao melhor grau de pertença evidencia que 83% da área total foi classificada apresentando valores relativos ao melhor grau de pertença compreendidos no intervalo]90,100] e apenas 4.8% apresenta valores para a melhor classificação compreendidos no intervalo [0, 70]. Estes resultados são visíveis na figura 4.25 e foram obtidos a partir dos dados apresentados no quadro 4.15.

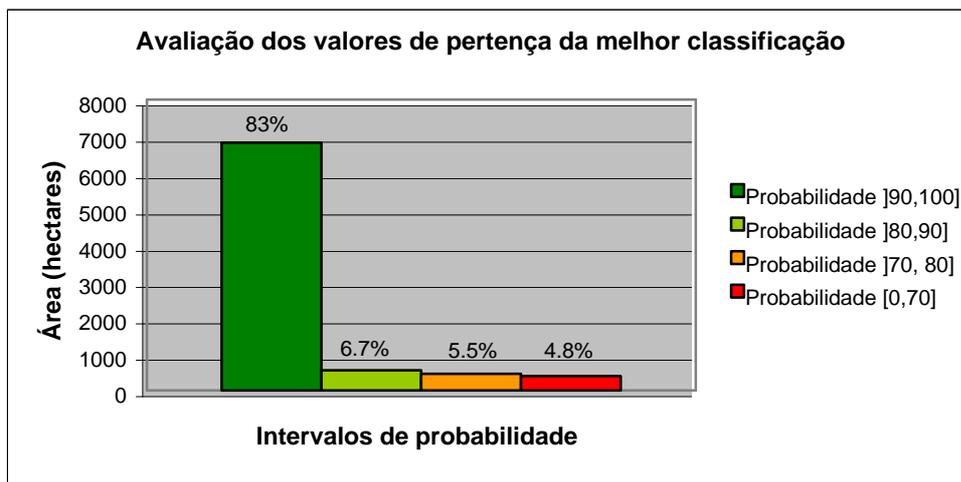


Figura 4.25 - Avaliação dos valores de pertença da melhor classificação do mapa final

No quadro 4.16 é apresentada a quantificação, para cada classe, da área correspondente aos objectos atribuídos apenas com um grau de pertença de '1' (total pertença) a essa classe e a respectiva percentagem face à área total da classe. Para as classes que não apresentaram uma total pertença a uma só classe foi analisada a classificação associada ao segundo melhor grau de pertença e calculada a percentagem da área face à área total da classe.

Quadro 4.16 – Quantificação para cada classe, que não teve uma total atribuição a uma só classe, das classes correspondentes à segunda melhor classificação

Melhor Classe	Área(ha)	%	Segunda Melhor Classe	Área(ha)	%
Áreas residenciais descontínuas	233.2	36.8	Áreas residenciais contínuas	16.3	2.6
			Áreas agrícolas com culturas anuais	181.5	28.6
			Zonas agrícolas heterogéneas	149.9	23.6
Áreas residenciais contínuas	126	46.2	Áreas residenciais descontínuas	94.2	34.9
			Áreas agrícolas com culturas anuais	27.7	10.3
			Zonas agrícolas heterogéneas	16.6	6.1
Serviços de utilidade pública	4	100.0			
Zonas industriais	107.5	91.3	Áreas residenciais descontínuas	6	5.1
			Rede viária	4.3	3.7
Rede viária	17.9	20.1	Áreas residenciais contínuas	16.4	18.4
			Áreas residenciais descontínuas	14.6	16.4
Saibreira	10	100.0			
Zonas de lixeira	22	100.0			
Estaleiros	33.7	100.0			
Espaços verdes urbanos	17.9	77.8	Áreas agrícolas com culturas anuais	2.2	9.6
			Zonas agrícolas heterogéneas	2.3	10.0
Infra-estruturas desportivas	4.5	100.0			
Áreas agrícolas com culturas anuais	93.2	29.3	Zonas agrícolas heterogéneas	176.2	55.5
Zonas agrícolas heterogéneas	88.5	44.8	Áreas agrícolas com culturas anuais	61.2	31.0
Folhosas	138.6	7.7	Resinosas	1680.9	92.2
Resinosas	597.8	13.3	Folhosas	3878.2	86.3
Vegetação arbustiva e herbácea	34.1	55.2	Áreas agrícolas com culturas anuais	36.2	58.6
			Zonas agrícolas heterogéneas	14.6	23.6
Áreas corte floresta	81.9	100.0			

Pela leitura dos valores que constam no quadro verifica-se que os objectos atribuídos aos usos do solo Serviços de utilidade pública, Saibreira, Zonas de lixeira, Estaleiros, Infra-estruturas desportivas e Áreas corte floresta apresentam uma total pertença às classes, podendo concluir-se que, para estas classes de informação, a ambiguidade é nula. Da área classificada como Folhosas e Resinosas apenas 7.7% e 13.3%, respectivamente, foi atribuída com uma total pertença. Ao analisar a classificação associada ao segundo melhor grau de pertença constatou-se que, para cerca de 92% da área atribuída à classe *Folhosas*, a classe relativa à segunda melhor classificação é *Resinosas* e, para cerca de 86% da área atribuída à classe *Resinosas*, a classe relativa à segunda melhor classificação é *Folhosas*. A ambiguidade existente na classificação é entre ambas as classes. O mesmo acontece entre as Áreas agrícolas com culturas anuais e as Zonas agrícolas heterogéneas e entre as Áreas residenciais contínuas e descontínuas e Áreas residenciais contínuas. As Áreas residenciais descontínuas apresentaram também uma certa ambiguidade com as Zonas agrícolas heterogéneas, o que é compreensível pois na área de estudo existem, no interior do

aglomerado urbano, inúmeros prédios e habitações unifamiliares com quintais, um facto que pode justificar esta ambiguidade.

O quadro 4.17 apresenta, para cada classe, a área e a correspondente percentagem face à área total da classe que foi identificada com pouca, média e muita incerteza. Os resultados obtidos encontram-se também ilustrados pelas figuras 4.26 e 4.27.

Quadro 4.17- Avaliação da incerteza das classes identificadas no mapa final

Classes	Pouca incerteza		Média incerteza		Muita incerteza	
	Área		Área		Área	
	ha	%	ha	%	ha	%
Áreas residenciais contínuas (II)	187.7	69.1	33.2	12.3	50.3	16.8
Áreas residenciais descontínuas (II)	397.6	62.7	94.1	14.8	142.6	22.5
Serviços de utilidade pública e administ. local (IV)	3.9	100				
Zonas industriais (II)	111	94.3	3.1	2.6	3.6	3
Rede viária (II)	31.2	35.1	18.4	20.6	39.3	44.1
Saibreira (III)	10	100				
Zonas de lixeira (III)	22	100				
Estaleiros (III)	33.7	100				
Espaços verdes urbanos (II)	17.4	75.7	0.3	1.3	5.3	22.9
Infra-estruturas desportivas (III)	4.5	100				
Áreas agrícolas com culturas anuais (II)	67.6	21.3	49.1	15.4	201	63.3
Zonas agrícolas com culturas heterogéneas (II)	63.9	32.4	31.9	16.1	101.9	51.5
Folhosas (III)	142.4	7.9	208.6	11.7	1438.6	80.4
Resinosas (III)	616.1	6.9	73	1.6	3804.9	84.7
Vegetação arbustiva e herbácea (III)	45	72.8	3.8	6.1	13	21
Áreas corte floresta (III)	81.9	100				
Total hectares	1835.9		515.5		5800.5	
%	22.5		6.3		71.2	

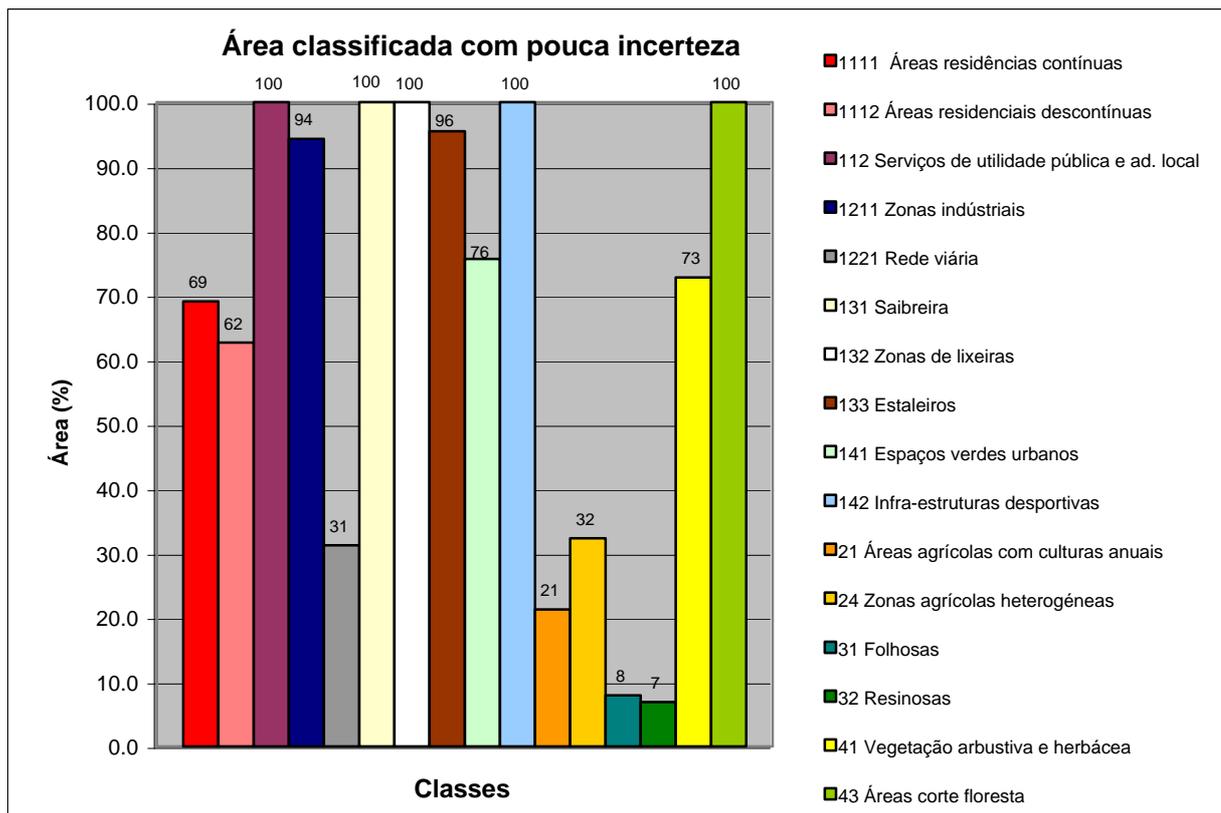


Figura 4.26 - Percentagem de área relativamente a cada classe atribuída com pouca incerteza.

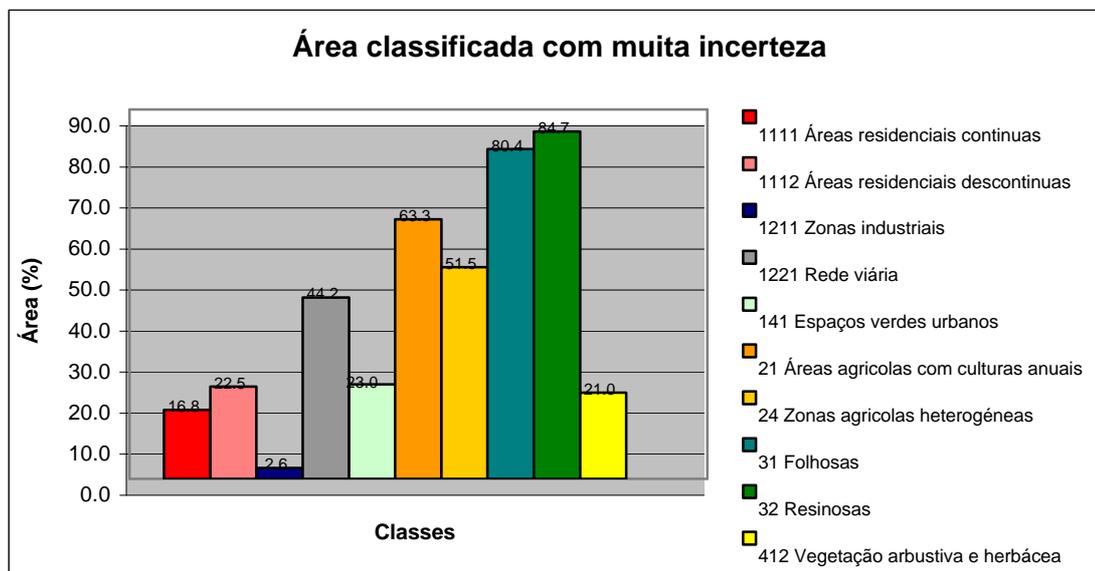


Figura 4.27 - Percentagem de área relativamente a cada classe atribuída com muita incerteza.

A partir dos valores apresentados no quadro 4.17 pode concluir-se que para as classes Artificiais e Meios semi-naturais, a ambiguidade da classificação é menor do que a

obtida para as classes Florestais e Agrícolas. A maioria das classes, como sejam Serviços de utilidade pública e administração local, Saibreira, Estaleiros, Infra-estruturas desportivas e Áreas corte floresta foram atribuídas com valores de pertença, para a melhor classificação, bastante elevados ou uma total pertença, conforme consta no quadro 4.16. As classes Zonas industriais e Espaços verdes urbanos apresentam, respectivamente, 94.3% e 75.7 % da sua área classificada com pouca incerteza, 2.6% e 1.3% foi atribuída com média incerteza e 3% e 22.9% com muita incerteza. A classe Rede viária é a classe artificial que apresenta maior incerteza na classificação (44.1%). As classes Áreas residenciais contínuas e Áreas residenciais descontínuas apresentam, respectivamente, 69.1% e 62.7 % da sua área classificada com pouca incerteza, 12.3% e 14.8% com média incerteza e 16.8% e 22.5% com muita incerteza o que revela a existência de ambiguidade na discriminação destas classes. Relativamente às classes Áreas agrícolas com culturas anuais e Áreas Agrícolas com culturas heterogéneas verificou-se que 21.3% e 32.4% da sua área foi atribuída com valores superiores a 80% para a melhor classificação e valores inferiores a 50% para a segunda melhor classificação, i. e. pouca incerteza, contudo, 63.3% e 51.5%, respectivamente, apresentaram muita incerteza na classificação.

Os objectos que apresentam maior incerteza foram os atribuídos às classes Resinosas e Folhosas: 6.9% e 7.9% da área classificada apresentou pouca incerteza; 1.6% e 11.7% média incerteza e a restante área contém muita incerteza. Constatou-se que 93.1% da área classificada como Resinosas apresentou valores superiores a 80% para a melhor classificação e 78.5% da área classificada como Folhosas apresentou valores superiores a 80% (resultados inferidos a partir do quadro 4.15). A muita incerteza temática associada à classe Resinosas deve-se fundamentalmente à proximidade de valores obtidos entre a melhor classificação (Resinosas) e a segunda melhor classificação (Folhosas) ocorrida para 84.7% da área atribuída a esta classe (quadro 4.16). Apesar destas classes apresentarem muita incerteza temática, a precisão do produtor foi de 85% e 88% e a precisão do utilizador foi de 65% e 95%, respectivamente. Comparando com resultados obtidos por outros estudos nacionais, em que se utilizou a informação espectral ao nível do *pixel*, os resultados obtidos no presente estudo revelam-se superiores. No projecto 'Abordagens Multiestratégicas para classificação de Imagens de Satélite - Aplicação numa Zona Florestal' efectuado no âmbito do programa 'Estímulo à investigação no domínio do ordenamento do território e do desenvolvimento urbano' (Campagnolo e Caetano, 1997b), por exemplo, os classificadores convencionais, aplicados às imagens Landsat utilizadas no estudo, apresentaram dificuldades para distinguir espectralmente as classes florestais. A informação obtida para as classes Resinosas e Folhosas apresentou, respectivamente, para a precisão do utilizador 11% e 58.5% e para a precisão do produtor 71% e 46.8%.

Dos resultados apresentados no quadro 4.15 e 4.17 pode inferir-se que, do total de área abrangida pela zona em estudo (8152 ha), 14.8% foi classificada como Área artificial, 6.3% como Ocupação agrícola, 77.1% como Floresta e 1.8% como Meios semi-naturais. A análise da incerteza temática da classificação é fortemente influenciada pelos resultados obtidos na discriminação das classes Folhosas e Resinosas, verificando-se que 22.5% da área total foi classificada com pouca incerteza, 6.3% com média incerteza e 71.2% com muita incerteza.

Em seguida é apresentada uma análise comparativa entre a avaliação da precisão, a partir da matriz de erro, e a análise da incerteza. Esta comparação teve como objectivo verificar se os dois métodos de avaliação da qualidade se complementam e eventualmente a análise da incerteza poderá contribuir para a diminuição do trabalho de campo necessário à construção da matriz de erro.

Da análise comparativa efectuada conclui-se que:

- a) as classes 112 (Serviços de utilidade pública e administração local), 131 (Saibreiras), 132 (Zonas de lixeira), 133 (Estaleiros), 141 (Espaços verdes urbanos) e 142 (Infra-estruturas desportivas), que apresentaram valores relativamente à incerteza temática muitos baixos e nalguns casos inexistentes, obtiveram também valores para a precisão bastante elevados. Como estas classes não possuíram um número significativo de pontos de validação, devido a ter sido adoptada uma amostra aleatória, não contribuindo por isso significativamente para os índices de precisão, os resultados da análise da incerteza serviram para confirmar que estas classes foram bem identificadas.
- b) as classes 1111 (Áreas residenciais contínuas) e 1112 (Áreas residenciais descontínuas), que apresentavam alguma incerteza na classificação apresentaram também valores médios de precisão.
- c) para a classe 1211 (Zonas industriais), 93% da área foi atribuída com pouca incerteza tendo-se verificado que 91.3% apresentou total pertença; em termos de precisão do utilizador o resultado obtido foi de 100% (não revelou erros de comissão). Contudo constataram-se erros de omissão consideráveis, pois a precisão do produtor foi de 76%.
- d) a classe 1221 (Rede viária) revelou a maior incerteza temática das classes artificiais, sendo também a que apresentou valores mais baixos de precisão.
- e) relativamente às classes não artificiais, a classe 32 (Resinosas), que em termos de incerteza apresentava valores muitos elevados (87% da sua área foi atribuída com muita incerteza), obteve valores de precisão do produtor e do utilizador bastante elevados, 88% e 95%, respectivamente. A informação da matriz de erro

conferiu confiança aos resultados obtidos.

- f) As restantes classes, não artificiais, não revelaram grandes surpresas ou contradições face aos valores obtidos para a incerteza temática.

A comparação entre os resultados obtidos na avaliação da precisão a partir da matriz de confusão e a análise da incerteza veio evidenciar que, efectivamente, a análise da incerteza complementa a avaliação da precisão conforme se constatou, e.g., com as classes Zonas industriais, Folhosas e Resinosas. Por outro lado, embora a matriz de confusão apresente uma importante informação relativamente à qualidade das classes, essa análise é efectuada com base em amostras e, muitas vezes, estas podem não ser uma amostra da população, tal como aconteceu, por exemplo, com as classes 112 (Serviços de utilidade pública e administração local), 131 (Saibreiras), 132 (Zonas de lixeira), 133 (Estaleiros), 141 (Espaços verdes urbanos) e 142 (Infra-estruturas desportivas). Relativamente a estas classes, a análise da incerteza veio confirmar a qualidade da classificação efectuada.

Quando os objectos classificados apresentam uma total pertença a uma só classe ou pouca incerteza na sua classificação (o maior grau de pertença com que os objectos foram atribuídos a uma classe é muito elevado e o segundo melhor grau de pertença a outra classe é muito baixo), o trabalho de campo para avaliar a qualidade destas classe poderá ser evitado.

A representação gráfica da incerteza temática foi efectuada com base nos critérios definidos relativamente aos intervalos de probabilidade considerados representativos da pouca, média ou muita incerteza. O mapa da incerteza produzido no estudo, ao ser sobreposto, em termos visuais, ao mapa da classificação final, permitirá ao utilizador, caso pretenda, avaliar as zonas em que existe muita, pouca ou média incerteza na classificação (ver anexo 8). A figura 4.28 ilustra, como exemplo, a classificação de uma área da imagem com sobreposição da informação relativa à incerteza da classificação. As classes de ocupação do solo estão identificadas por cor opaca, enquanto que a trama identifica a incerteza; como a trama é transparente permite visualizar a classificação em simultâneo.

O *software* eCognition, embora efectue uma representação gráfica da incerteza temática, não permite a sobreposição da informação da incerteza com a classificação. Com o tipo de representação desenvolvida no estudo o utilizador pode visualizar simultaneamente, e de forma sobreposta, a distribuição espacial da incerteza associada a cada mancha da classificação, o que constitui uma mais valia importante para a análise da qualidade da informação.

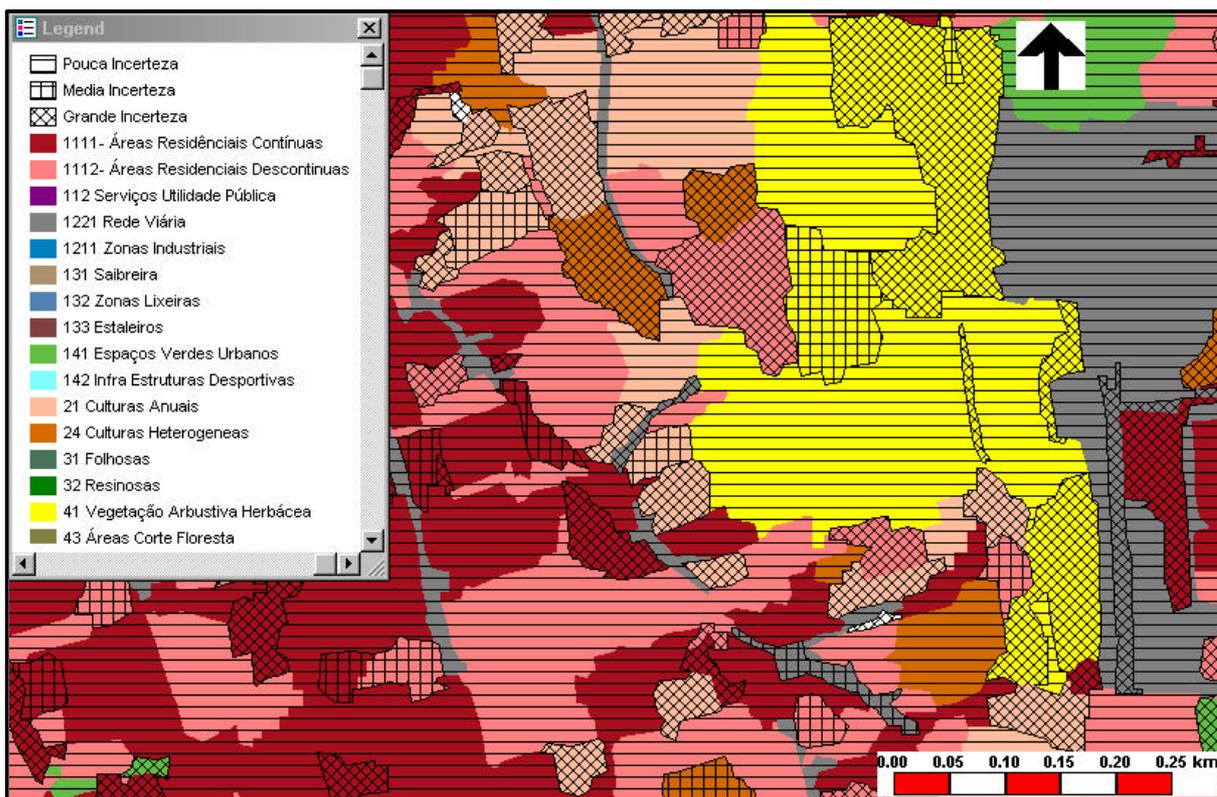


Figura 4.28 - Classificação da imagem com sobreposição da informação relativa à incerteza da classificação. As classes de ocupação do solo estão identificadas por cor, enquanto que a trama identifica a incerteza.

4.10 Avaliação da dinâmica da ocupação do solo

Para avaliar a dinâmica da ocupação do solo de 1990 para 2000 foi utilizada a COS'90 (Carta de Ocupação do Solo de 1990) e o mapa produzido neste estudo. A comparação entre a classificação efectuada a partir da imagem de satélite IKONOS (COS'00) e a COS'90 foi realizada com dois objectivos: análise da dinâmica da ocupação do solo conforme referido e avaliação qualitativa da COS'00.

Como os mapas de ocupação do solo efectuados em 1990 e 2000 têm características técnicas diferentes era esperado que surgissem alguns problemas e que não fosse possível efectuar uma análise rigorosa da dinâmica. Por exemplo, na área de estudo não existe uma forte componente agrícola, as áreas com ocupação agrícola restringem-se, na sua maioria, a pequenos quintais com uma área inferior a meio hectare que, na classificação da COS'90, foram integrados nas áreas residenciais descontínuas conforme ilustra a figura 4.29, mas que na COS'00 foram classificadas separadamente.

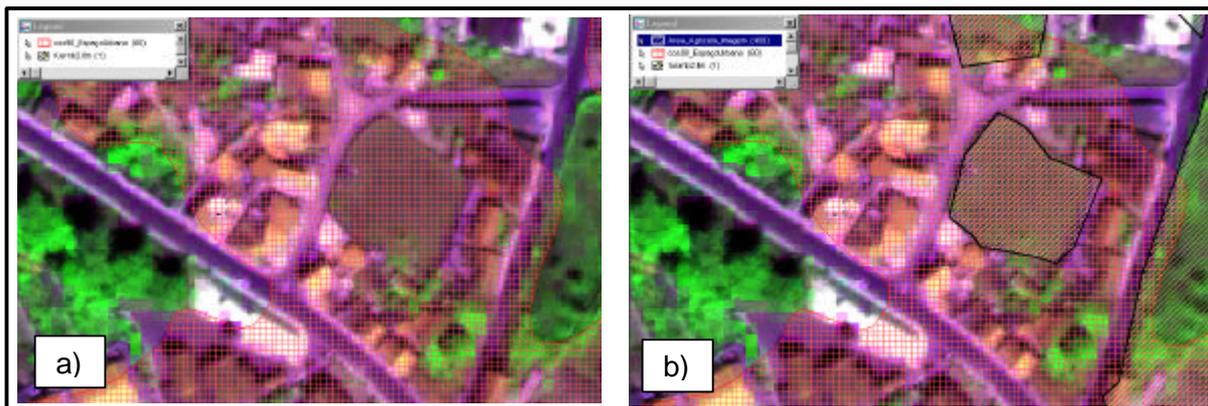


Figura 4.29 – Exemplo de diferenças de classificação entre a COS'90 e a COS'00 devido a características técnicas diferentes. Fig. 4.29 a) uma área da imagem IKONOS (RGB 341) com a sobreposição da classe identificada na COS'90 como Zona residencial descontínua (trama vermelha). Fig. 4.29 b) representa a mesma área com a sobreposição da classe Área com ocupação da agrícola identificada no estudo (linha a preto).

Relativamente à avaliação qualitativa, foram efectuadas análises às classes consideradas imutáveis (e.g., Áreas artificiais) e se existiam transições impossíveis, como sejam áreas classificadas como residencial em 1990 e que tivessem sido classificadas como área industrial ou florestal em 2000. Esta análise foi efectuada entre as classes do nível 1 da nomenclatura e entre as classes artificiais do nível 2 da nomenclatura.

Como a nomenclatura de referência da COS'90 é diferente da nomenclatura de referência da COS'00, para realizar a comparação entre as duas Cartografias de Ocupação do Solo foi utilizada a tabela de reclassificação da legenda COS'90 para a legenda da carta CORINE Land Cover (IGP) e efectuada igualmente a reclassificação da legenda utilizada na classificação da área de estudo, também para a legenda CORINE.

Na figura 4.30 é apresentado o resultado da comparação entre a ocupação do solo em 1990 e em 2000 relativamente à informação correspondente ao nível 1 da nomenclatura de referência (Áreas artificiais, Áreas com ocupação agrícola, Floresta e Meios semi-naturais).

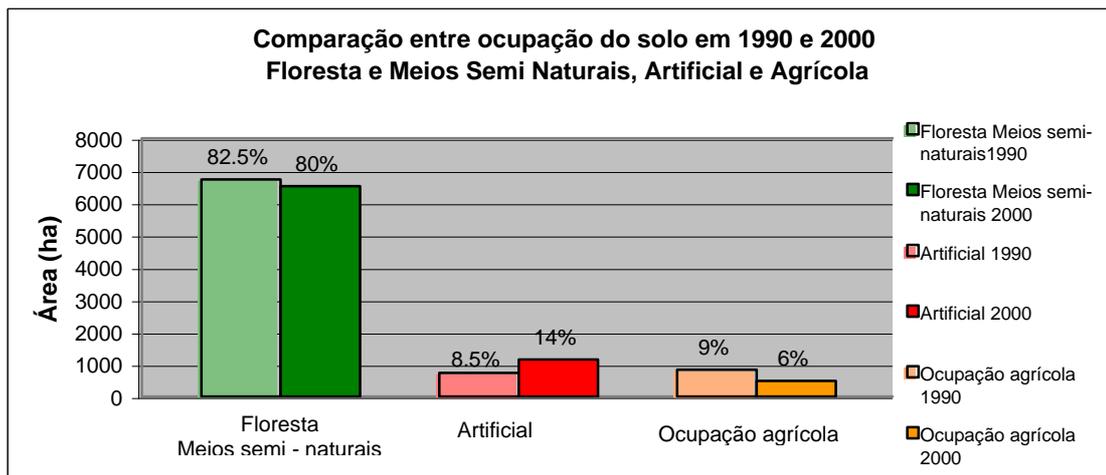


Figura 4.30 - Comparação entre a ocupação do solo de 1990 e 2000 relativamente às Áreas artificiais, Agrícolas e Florestal e Meios semi- naturais.

Da leitura da figura 4.30, conclui-se que houve um aumento da área residencial de 5.5% em detrimento da área agrícola (-3%) e florestal (-2.5%), o que era de esperar dada a expansão urbana e industrial da área em estudo nos últimos 10 anos. Estes dados revelam que a classificação automática da imagem IKONOS permitiu detectar a expansão urbana mesmo quando comparada com cartografia derivada de interpretação visual de fotografia aérea.

Na figura 4.31 são apresentadas as transferências de ocupação do solo de 1990 para 2000 relativamente à informação correspondente ao nível 1 da nomenclatura de referência (Áreas artificiais, Áreas com ocupação agrícola, Floresta e Meios semi-naturais).

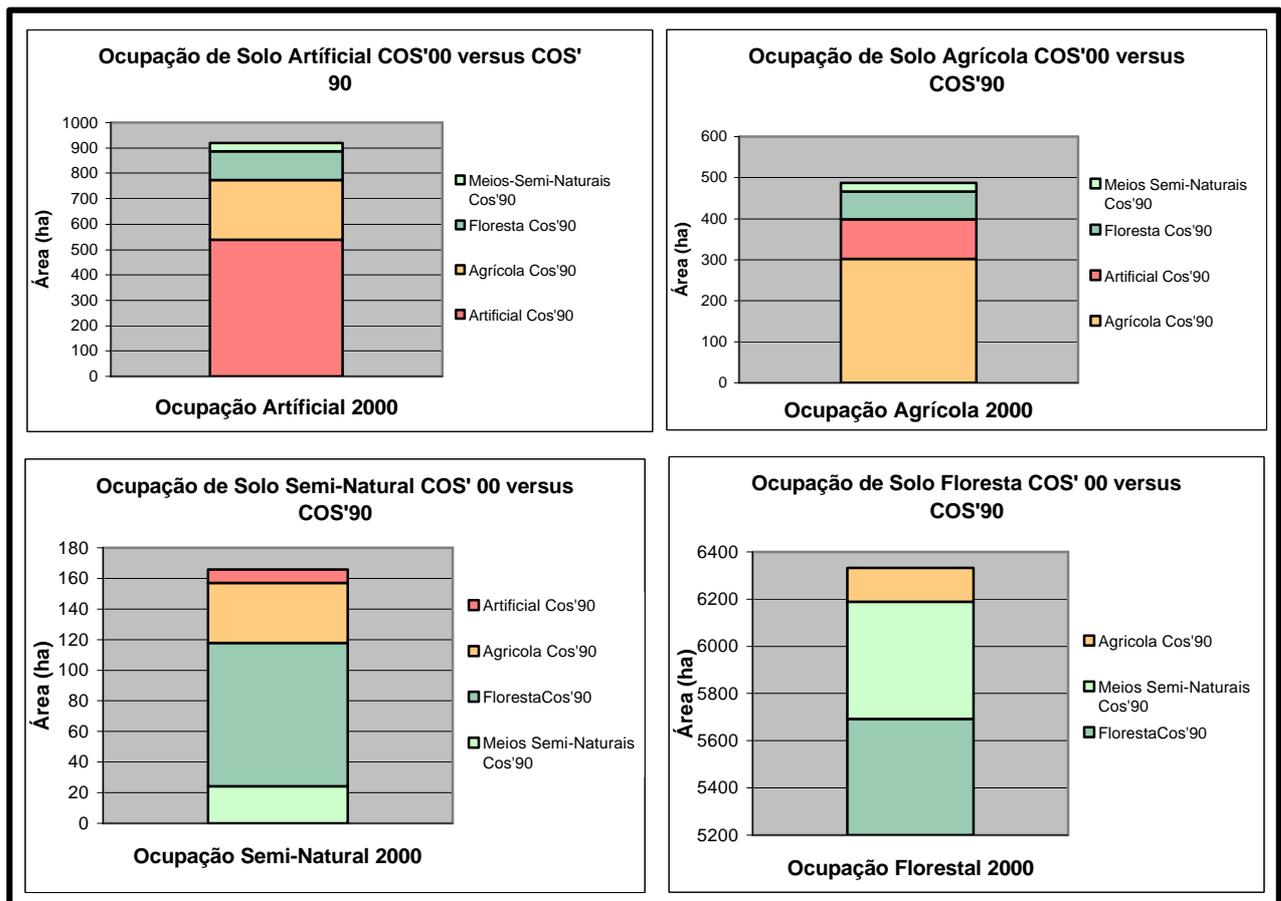


Figura 4.31 - Transferências de ocupação do solo de 1990 para 2000 relativamente à informação correspondente ao nível 1 da nomenclatura de referência Artificial, Ocupação agrícola, Floresta e Meios semi-naturais

Ao analisar as transferências de ocupação do solo de 1990 para 2000 relativamente à informação correspondente ao nível 1, não se detectaram transferências impossíveis. Constatou-se apenas que, da área classificada em 2000 como Áreas com ocupação agrícola (487 ha), 20% corresponde a área classificada na COS'90 como Artificial. A razão da aparente transferência de ocupação artificial para ocupação agrícola, e que pode parecer uma transferência impossível, deve-se ao facto, conforme acima referido, de na classificação da COS'90 terem sido integradas nas Áreas residenciais descontínuas Áreas com ocupação agrícola (figura 4.29), por terem uma área mínima inferior à área mínima de representação considerada para a classificação. A área mínima da COS'90 é de 10 000m² e no caso da classificação efectuada a área mínima é de 64m². Esta diferença entre a área mínima reflectiu-se essencialmente na classificação das Áreas com ocupação agrícola e Meios semi-naturais. Uma forma de ultrapassar este problema passaria por aplicar ao mapa produzido COS'00 operações de generalização recorrendo, por exemplo, a um *software* que efectuasse estas operações de forma automática. Este tipo de *softwares* específicos não se

encontra ainda disponível no mercado segundo Kilpelainen (1999). O Grupo de Detecção Remota do Instituto Geográfico Português (IGP) tem vindo a desenvolver duas aplicações denominadas de MapGen e RasterGen para generalização de Cartografia Temática em formato *raster* e vectorial, respectivamente (Carrão *et al.*, 2001; Caetano *et al.*, 2001). No entanto, não se utilizaram pois no momento da execução da tese as aplicações ainda estavam em desenvolvimento.

Verificou-se também que, da área classificada em 2000 como Ocupação agrícola, 13 % corresponde a área classificada na COS'90 como Floresta. Numa região que não possui uma forte componente agrícola e numa época em que cada vez se assiste mais ao abandono da agricultura, poderia também parecer duvidosa a transição de ocupação florestal para ocupação agrícola. Contudo, através da análise da imagem, verificou-se que efectivamente é uma transição correcta e na figura 4.32 são visíveis, como exemplo, áreas classificadas com Ocupação agrícola e que, na classificação da COS'90, correspondiam a áreas de Floresta .

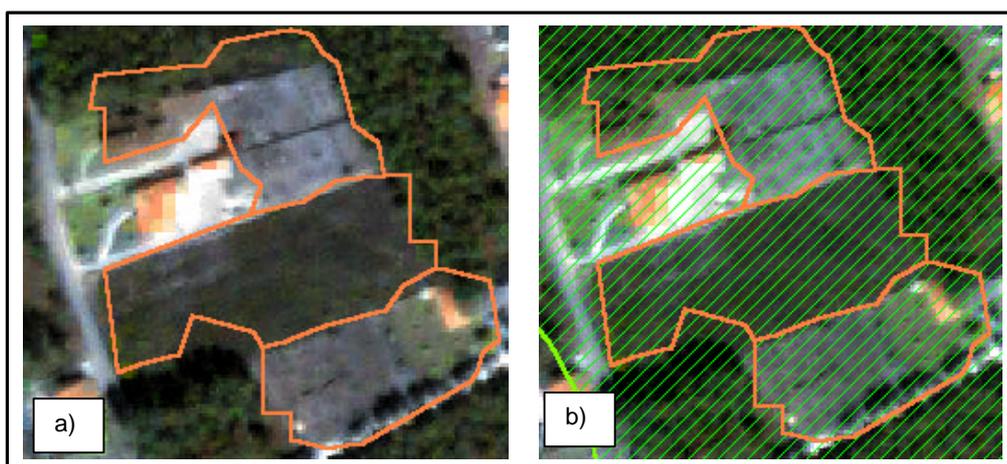


Figura 4.32 – Transferência de ocupação do solo florestal em 1990 para ocupação do solo agrícola em 2000. Fig. 4.32 a) Áreas classificadas como Áreas com ocupação agrícola em 2000 representadas a cor laranja. Fig. 4.32 b) A mesma área com a sobreposição da classificação de 1990 que correspondia a Ocupação florestal representada com trama verde (imagem IKONOS RGB 321).

Nas figuras 4.33, 4.35 e 4.37 são apresentadas as transferências de ocupação do solo de 1990 para 2000 relativamente às classes artificiais do nível 2 da nomenclatura de referência: 11 (Zonas com dominância de habitação), 12 (Zonas com revestimento predominantemente artificializado) e 13 (Zonas alteradas artificialmente sem vegetação).

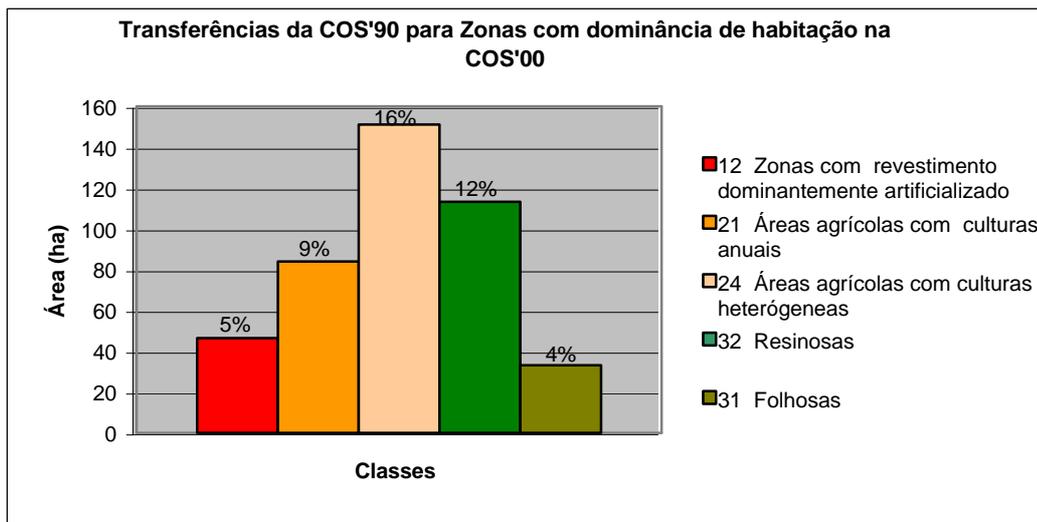


Figura 4.33 - Transferências para Zonas com dominância de habitação.

Da área classificada em 2000 como Zonas com dominância de habitação (920 ha), 46% (441.6ha) resulta de transferências de ocupação do solo, de 1990 para 2000, relativamente à informação correspondente aos níveis 12, 21, 24, 32 e 31 da nomenclatura de referência.

Das transferências ocorridas, a única que pode ser considerada impossível é a transição de áreas que, na COS'90, foram classificadas como Zonas com revestimento predominantemente artificializado e que correspondem principalmente a áreas industriais. O facto de, na classificação actual, terem sido atribuídas a Zonas com dominância de habitação resulta de existirem usos do solo industriais no interior do tecido predominantemente habitacional com cobertura idêntica ao uso do solo com dominância de habitação, sendo difícil a sua classificação de forma automática. Um exemplo deste tipo de situações é visível na figura 4.34.

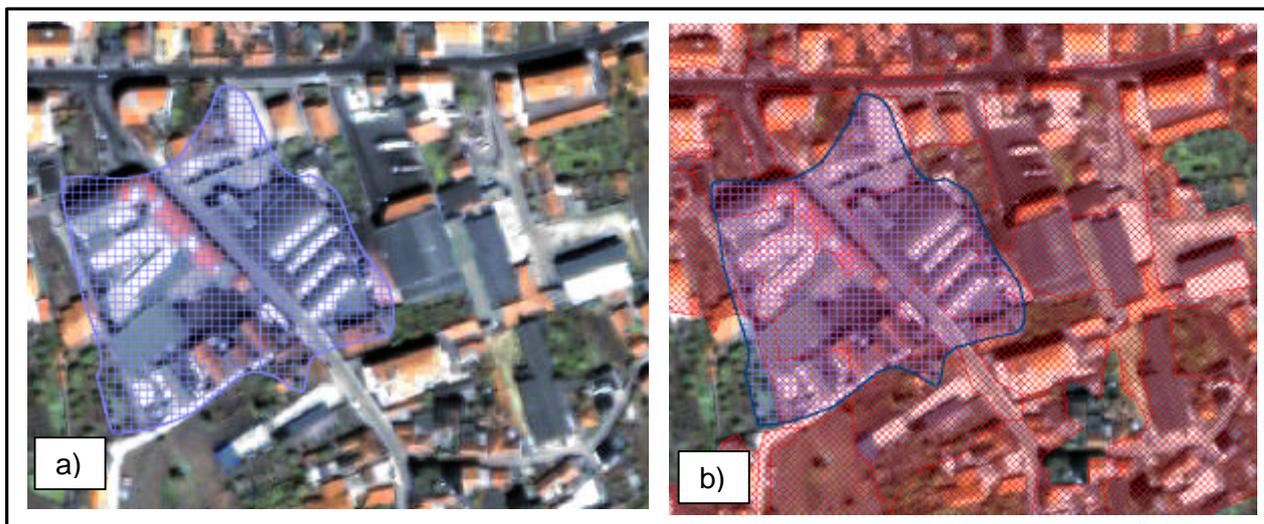


Figura 4.34 – Exemplo de uma transição impossível (imagem IKONOS RGB 321). a) área da imagem classificada na COS'90 como Zona industrial (trama azul). b) a mesma área com a sobreposição da classificação de Área com dominância de habitação efectuada no estudo (trama vermelha)

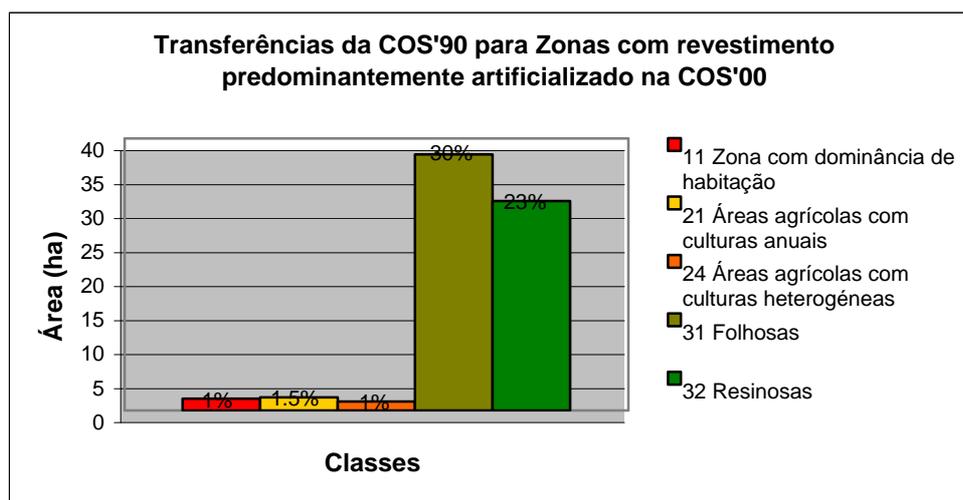


Figura 4.35 – Transferências para Zonas com revestimento predominantemente artificializado

Da área classificada em 2000 como Zonas com revestimento predominantemente artificializado, 56.5% resulta de transferências de ocupação do solo, de 1990 para 2000, relativamente à informação correspondente aos níveis 11, 21, 24, 31 e 32 da nomenclatura de referência. Pela observação dos valores da figura 4.35, 1% da actual área com revestimento predominantemente artificializado tinha, em 1990, uma ocupação com dominância de habitação, 2.5% uma ocupação do solo agrícola (1.5% Áreas agrícolas com culturas anuais e 1% Áreas agrícolas com culturas heterogéneas), 53% florestal (30% Folhosas e 23% Resinosas).

De referir que a transferência de área, que em 1990 era ocupada por floresta e

actualmente é ocupada por Zonas com revestimento predominantemente artificializado, deve-se a uma forte expansão industrial com a criação de novas áreas industriais e que foram correctamente identificadas na classificação da imagem de satélite. Na figura 4.36 são apresentadas duas imagens, ortofoto de 1995 e imagem IKONOS 2000, de uma mesma zona industrial, que evidencia a transferência de área florestal para Zonas alteradas artificialmente sem vegetação.

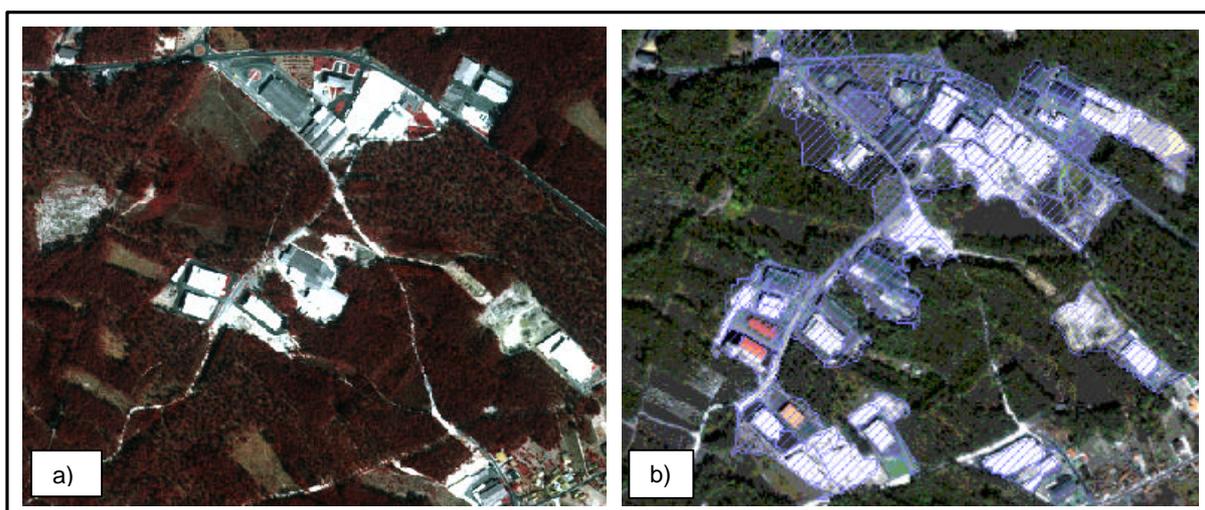


Figura 4.36 – As Imagens ilustram a transferência de Floresta para Zonas alteradas artificialmente sem vegetação. Fig 4.36 a) extracto de um ortofoto de 1995. Fig. 4.36 b) extracto da imagem fusão do satélite IKONOS de 2000 (RGB 321) sobreposta com a classificação (cor azul) das áreas industriais, efectuada no estudo.

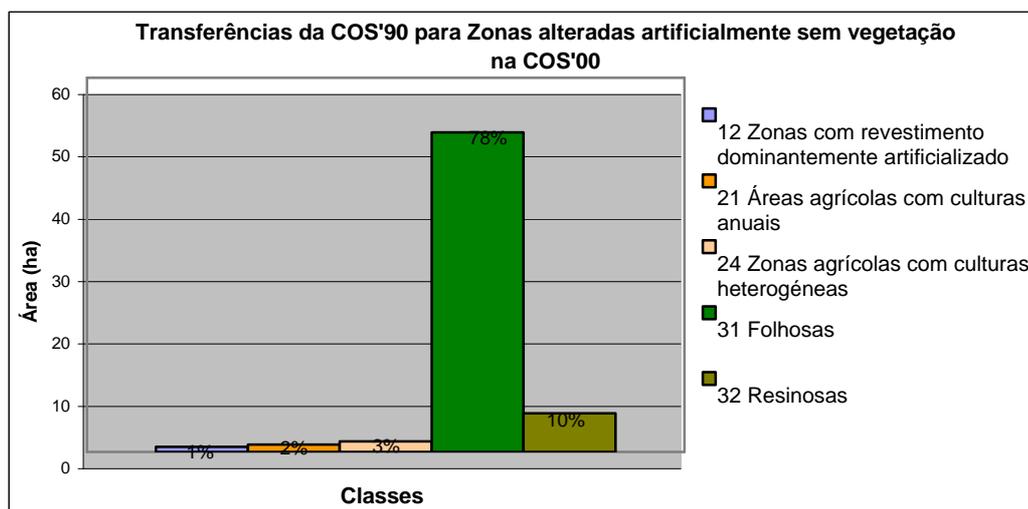


Figura 4.37 - Transferências para Zonas alteradas artificialmente sem vegetação

Da área classificada em 2000 como Zonas alteradas artificialmente sem vegetação, 78% resulta de uma transferência de ocupação do solo florestal conforme ilustra a figura 4.37.

Esta transferência não constitui uma transição impossível. A área, que em 1990 era ocupada por floresta e actualmente é ocupada por zonas com revestimento predominantemente artificializado, deve-se à criação de uma área de aterro Lixeira e ao crescimento da exploração de uma saibreira, que foram correctamente identificadas na classificação da imagem de satélite. Na figura 4.38, pode observar-se a classificação da COS'90 sobreposta à imagem IKONOS, em que é visível a área actualmente ocupada pela saibreira e aterro lixeira que em 1990 tinha uma ocupação florestal.



Figura 4.38 - Classificação da COS'90 sobreposta à imagem IKONOS (RGB 321) em que é visível a área actualmente ocupada pela saibreira e aterro lixeira que em 1990 tinha uma ocupação florestal (cor verde).

Da análise comparativa efectuada entre a classificação da COS'90 e a COS'00 não se detectaram transições impossíveis relevantes. As diferenças ocorridas deveram-se fundamentalmente: (1) à diferença da área mínima que se reflectiu principalmente nas áreas agrícolas como referido no início desta secção; (2) limitação da classificação automática para identificar usos do solo, nomeadamente nas áreas urbanas, em que estes são definidos mais em termos da sua função do que nas suas características espectrais ou da forma.

Apesar dos mapas terem especificações técnicas diferentes pode-se concluir que as imagens IKONOS, quando exploradas com a metodologia adequada, permitem obter uma boa classificação e detectar as grandes alterações mesmos quando comparadas com mapas derivados de interpretação visual de fotografia aérea.

4.11 Mapa do uso do solo melhorado pela integração de dados SIG

Para realizar a integração da informação de ocupação do solo extraída da imagem com a informação auxiliar existente, estruturada em ambiente SIG Vectorial, foi efectuada a conversão, com o *software* ArcView, do formato *raster* para o formato vectorial do Mapa de Ocupação do Solo produzido, e das imagens segmentadas registadas nos níveis 2, 3 e 4 (a informação em formato vectorial correspondente ao nível 1, como continha 662 340 polígonos, não foi utilizada devido ao seu peso em termos computacionais). A conversão das imagens segmentadas registadas nos níveis 2, 3 e 4 foi necessária para proceder à análise da incerteza apresentada na secção 4.9. Na figura 4.39 são visíveis os polígonos, resultantes da conversão para formato vectorial, da classificação da imagem e dos objectos imagem obtidos na fase de segmentação (a versão 2.0 do eCognition já permite a exportação da informação para o formato vectorial).

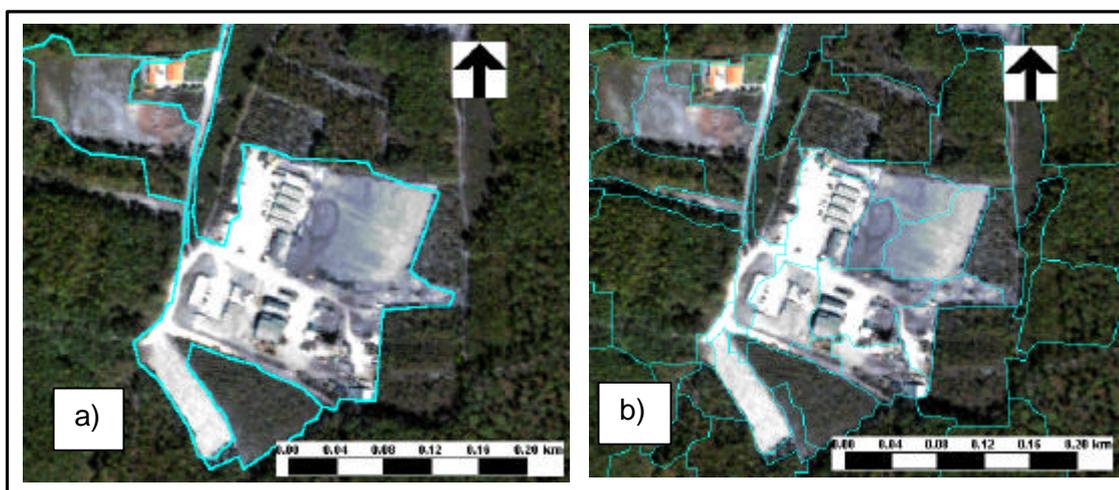


Figura 4.39 – Conversão da classificação da imagem e da segmentação do nível 3. Fig. 4.39 a) polígonos correspondentes às manchas classificadas, sobrepostos à imagem IKONOS (RGB 321). Fig. 4.39 b) polígonos correspondentes aos objectos imagem

A informação que resulta do processo de classificação contém apenas a informação gráfica das manchas de classificação (às quais está associado apenas o código da classe). A informação alfanumérica dos graus de pertença, com que os objectos foram atribuídos às classes para a primeira, segunda e terceira melhor classificação, está associada aos objectos imagem resultante da segmentação. Esta informação, fornecida num ficheiro alfanumérico, foi incorporada no SGBD ACCESS (produto *Microsoft*). As figuras 4.40 e 4.41 apresentam, respectivamente, os atributos da informação de ocupação do solo associada às manchas obtidas com a classificação e os atributos associados aos objectos imagem classificados.

ID	GRIDCODE	Legenda
5	115	Espaço Verde Urbano
4	69	Area Corte Floresta
3	69	Areas Corte Floresta
2	132	Culturas Heterogeneas
1	119	Areas_Residenciais

Figura 4.40 – Tabela contendo os atributos do Mapa de ocupação do Solo

ID	Best Class	Best Class ID	Best Member Ship	Second Class	Second Class ID	Second Member Ship	Third Class	Third Class ID
5317	Resinosas	114	1	unclassified	-1	0	unclassified	-1
5318	Culturas Heterogeneas	132	0.775265	Culturas Anuais	131	0.495694	unclassified	-1
5319	Resinosas	114	1	unclassified	-1	0	unclassified	-1
5320	Resinosas	114	1	unclassified	-1	0	unclassified	-1
5321	Resinosas	114	1	unclassified	-1	0	unclassified	-1

Figura 4.41 – Tabela contendo a informação da classificação dos objectos imagem efectuada com a base de conhecimento constituída pelo desenvolvimento hierárquico 2.

Para que a informação dos graus de pertença ficasse associado à informação gráfica dos objectos imagem foi necessário efectuar, em ambiente SIG, uma operação de *join*, tendo-se utilizado como campo comum o identificador dos objectos imagem. A cada polígono correspondente ao objecto imagem ficou, assim, associada a respectiva informação da classificação. Após esta operação foram calculadas as suas áreas passando esta informação a constar da tabela como atributo. Todo este procedimento foi necessário para se poder efectuar a análise de incerteza apresentada na secção 4.9. Um outro aspecto importante é que passa a ser possível uma maior flexibilidade de manipulação dos dados, como por exemplo, visualizar apenas os que satisfaçam um determinado valor de incerteza.

Relativamente à informação espacial do Mapa de Ocupação do Solo, foi também necessário efectuar uma operação de *join* para associar a informação do nome da classe à respectiva mancha classificada, tendo-se utilizado, como campo comum, o código identificador da classe.

Ao integrar os dados auxiliares com a informação extraída da imagem o resultado ficou mais enriquecido como se constata na figura 4.42 em que é feita a comparação entre uma área residencial com e sem integração dos dados. A informação auxiliar corresponde a: Serviços de utilidade pública e administração local (112); Zonas comerciais e financeiras (1212), Rede ferroviária (1222), Rede viária (1221), Zonas históricas e espaços culturais (143). A integração dos dados SIG não foi sujeita a validação pois a informação auxiliar está

correcta, devido à forma como foi levantada e ao controle de qualidade a que foi sujeita (o levantamento da informação que não existia nos serviços da CMMG envolveu a criação de equipas para recolha da informação em campo, e confirmação de situações de dúvida).

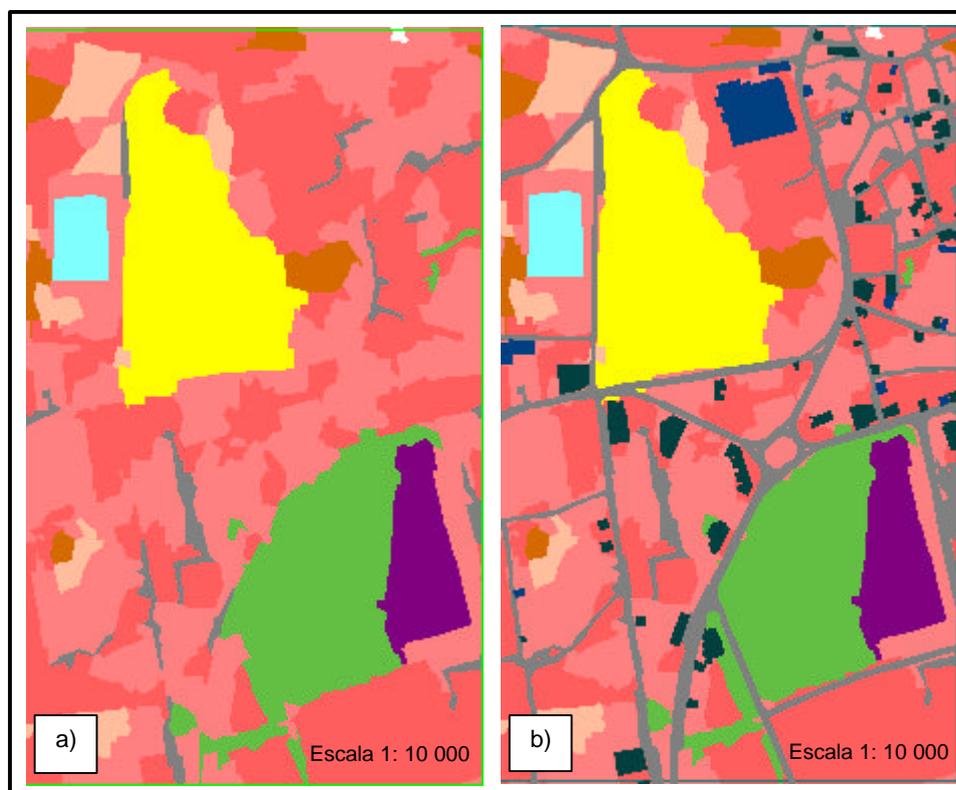


Figura 4.42 - Extracto do Mapa de Ocupação do solo produzido: Fig. 4.42 a) sem dados auxiliares; Fig. 4.42 b) com dados auxiliares.

A integração foi efectuada apenas por sobreposição dos temas. Para melhorar a integração dos dados seria necessário proceder a operações de análise espacial e operações de generalização. A figura 4.43 ilustra, como exemplo, um tipo de problemas que ocorreriam se se pretendesse extrair da área classificada como residencial contínua e descontínua, as áreas correspondentes à zona de comércio, serviços e rede viária. O resultado é visível na imagem d) da figura 4.43. Conforme se pode observar existem pequenas áreas que ficam isoladas (assinaladas na imagem por um círculo a preto). Este problema poderia ser resolvido, por exemplo, através de um processo de agregação. A ocorrência deste tipo de problemas deve-se, em parte, ao facto de as escalas da informação auxiliar e do Mapa de Ocupação do Solo produzido serem diferentes. A informação auxiliar foi produzida à escala 1:2000, pois teve como suporte a cartografia à escala 1:2000, e o Mapa de Ocupação do Solo foi obtido a partir de imagem de satélite com 4 metros de resolução espacial e efectuado para a escala 1:10 000. Neste estudo não serão abordados os processos de generalização porque saiem fora dos seus objectivos.

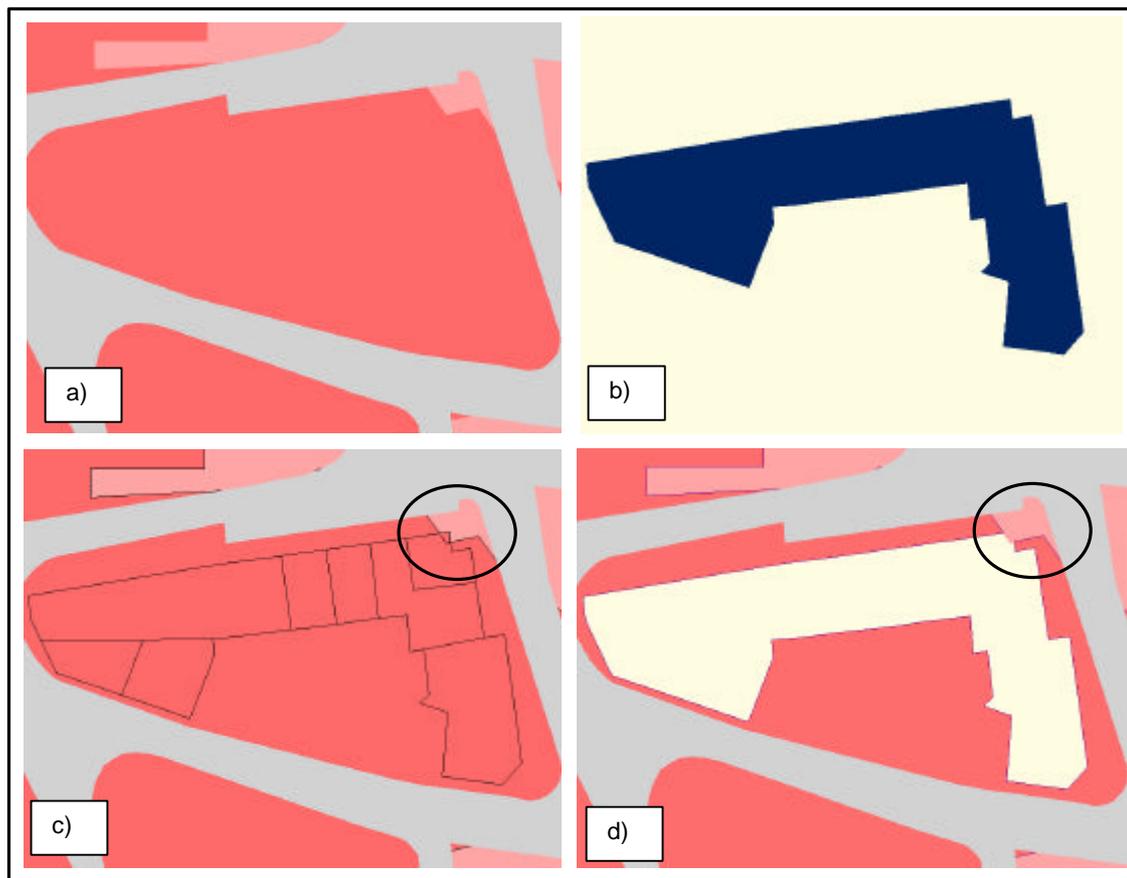


Figura 4.43 – Fig. 4.43 a) extracto do mapa de ocupação do solo em que são visíveis as classes Área residencial contínua (vermelho escuro) e Área residencial descontínua (cor vermelho claro) e Rede viária(cinzento claro); Fig. 4.43 b) o mesmo extracto com informação auxiliar correspondente a uma área comercial (azul escuro); Fig. 4.43 c) o resultado da operação de união dos temas Área residencial contínua e Zonas comerciais; Fig. 4.43 d) resultado da operação de extracção (circulo a preto assinala um dos problemas ocorridos).

Capítulo 5 – Conclusões

Para extrair a informação temática de imagens de grande resolução espacial foi desenvolvida e testada uma metodologia que se baseia na análise de imagens orientada por objectos e que consistiu nas seguintes fases:

- Segmentação da imagem para obter os objectos imagem utilizando o algoritmo multi-resolução. Foram efectuadas quatro segmentações com diferentes escalas para possibilitar a captura de estruturas correspondentes e permitir construir uma hierarquia de objectos. A construção desta hierarquia permitiu combinar as estruturas das diferentes escalas capturadas nas várias segmentações. Com a extracção dos objectos são calculados atributos espectrais, de forma, textura e topologia que constituem um conjunto de variáveis a serem utilizadas na fase da classificação.
- Construção de uma base de conhecimento estruturada sob a forma de uma hierarquia de classes. A classificação dos objectos é efectuada através do classificador do vizinho mais próximo (sendo necessário definir áreas de treino) ou através da classificação *fuzzy* (em cada classe as propriedades dos objectos que devem pertencer a essa classe são descritas através de funções de pertença).
- Análise e representação espacial da incerteza temática efectuada com base nos valores dos graus de pertença retidos no resultado da classificação de cada objecto relativamente à melhor e segunda melhor classificação. Este tipo de análise permitiu complementar a avaliação da qualidade da classificação efectuada a partir da matriz de erro. A representação espacial da incerteza da classificação (realizada com base nos critérios definidos relativamente aos intervalos de probabilidade considerados representativos da pouca, média ou muita incerteza), ao ser sobreposta ao mapa obtido, poderá ser utilizada, pelo utilizador dos dados, para avaliar as zonas em que existe incerteza.

A metodologia foi implementada em imagens IKONOS para produção de cartografia de ocupação do solo à escala 1: 10 000 e a área de teste situa-se no Concelho da Marinha Grande. O estudo realizado, com o método de análise de imagens orientada por objectos, aplicado a imagens IKONOS, foi o primeiro em termos nacionais e um dos primeiros em termos internacionais. O mapa final apresentou uma precisão global de 83%, tendo sido identificadas 16 classes.

Uma das conclusões a tirar do método é a de que, para se obterem bons resultados

na extracção da informação, é fundamental uma boa segmentação dos dados imagem em que os objectos criados estejam bem adaptados à estrutura dos objectos reais.

A segmentação é controlada principalmente através de um factor de escala que, indirectamente, determina o tamanho dos segmentos. Como não existe uma escala de objectos *standard*, é necessário analisar, para cada tipo de informação que se pretende extrair da imagem, qual ou quais as melhores escalas para efectuar a segmentação. Para obter o melhor resultado na segmentação de uma dada imagem, é essencial efectuar vários testes até se encontrarem os parâmetros de segmentação apropriados. De salientar que, ao efectuar repetidas segmentações de um extracto da imagem, os objectos reproduzidos são idênticos. Se se alterar o tamanho do extracto da imagem e mantiver os mesmos valores para os parâmetros de segmentação, o resultado altera-se, obtendo-se objectos imagem diferentes.

Por outro lado, é muito importante a correcta construção de regras de classificação, sendo para isso necessário um bom conhecimento dos atributos dos objectos (espectrais, forma, textura, topologia, hierarquia). Esta etapa é a mais morosa do processo de produção.

Ao incorporar relações de vizinhança, hierarquia, forma e textura, a possibilidade de diferenciação das classes é muito maior do que se se utilizar apenas a informação espectral. O método mostrou-se bastante eficaz, por exemplo, na extracção de informação dos espaços verdes e das infra-estruturas desportivas, para a qual foram essenciais, respectivamente, as relações de vizinhança e da forma dos objectos e correspondentes sub-objectos. Foi também possível identificar o urbano contínuo e descontínuo com base na percentagem de ocupação dos sub-objectos classificados como edificado habitacional. Este tipo de informação era impossível obter apenas com uma classificação ao nível do *pixel*.

O facto de se terem efectuado várias segmentações da imagem e construído uma hierarquia de objectos, permitiu combinar a informação relativa aos objectos dos diferentes níveis de segmentação, o que provou ser bastante eficiente, por exemplo: (1) na resolução da confusão espectral verificada entre classes artificiais e não artificiais, nomeadamente entre as áreas residenciais e áreas de floresta correspondentes a pinhal numa fase inicial de crescimento, com idade até 5/6 anos; (2) identificação das classes Floresta do nível II da nomenclatura, pois esta não teria sido possível apenas com os dados imagem IKONOS multiespectrais (4m) e sem a utilização da informação de textura obtida com base na informação dos sub-objectos a partir da banda do infravermelho próximo. No método utilizado, a informação de textura é obtida com base na informação dos sub-objectos, sendo necessário que os objectos e os sub-objectos difiram significativamente em termos de tamanho.

Por outro lado, o processo de classificação iterativo foi útil para que a classificação de determinados objectos pudesse servir como informação de contexto à classificação de outros (e.g., classificar os objectos como urbano contínuo e descontínuo com base na percentagem de ocupação dos sub-objectos classificados como edificado habitacional).

Os principais problemas encontrados na identificação de algumas classes estiveram relacionados com a confusão espectral (diferentes classes de uso do solo apresentarem assinaturas espectrais semelhantes) e com o facto de alguns dos objectos imagem criados não se apresentarem bem ajustados à estrutura dos objectos reais. Por exemplo, relativamente à identificação da informação referente à Rede viária, como não foi possível obter objectos imagem bem ajustados à estrutura dos objectos reais, a sua classificação não foi efectuada com uma precisão aceitável. O mesmo aconteceu com a Rede ferroviária (1222) tendo-se optado por não a identificar.

Embora a maioria das classes não artificiais tenha sido correctamente identificada até ao nível II da nomenclatura, verificaram-se alguns problemas na discriminação da classe Zonas com vegetação arbustiva e herbácea (41). Tal como na identificação das classes floresta do nível II da nomenclatura, esta só foi possível a partir da informação de textura obtida com base na informação espectral dos sub-objectos. O facto desta classe ter sido identificada a partir da imagem segmentada, em que a área mínima era de 500 m², levou a que áreas mais pequenas não fossem identificadas, ocorrendo muitos erros por omissão. Por outro lado, verificou-se uma total impossibilidade de extrair a informação a partir da imagem segmentada, directamente relacionada com a escala de interesse, cuja área mínima era de 64 m², dada a confusão espectral entre as classes Culturas Anuais (21), Áreas residenciais (111) e as Áreas de Floresta (numa fase inicial de plantação e de crescimento).

O critério utilizado para discriminar, de entre as Áreas residenciais, as Áreas residenciais contínuas das descontínuas, com base na percentagem de ocupação dos sub-objectos classificados como edificado habitacional, não foi totalmente eficaz. A eficácia da metodologia adoptada é dependente do tamanho dos objectos relativamente aos sub-objectos e da correcta classificação dos sub-objectos. Contudo, é de salientar que o método permitiu discriminar bastante bem as áreas urbanas residenciais.

Apesar da metodologia desenvolvida e dos dados IKONOS disponibilizarem imagens com uma maior resolução espacial, não é possível extrair todas as classes de informação da cobertura do solo com o nível de precisão temática e geométrica necessário apenas com os dados imagem.

Como forma de avaliar a operacionalidade da metodologia, foi efectuada uma análise

da dinâmica e uma avaliação qualitativa do mapa das alterações do uso do solo produzido. Este estudo foi realizado com base na comparação entre a classificação obtida e a Carta de Ocupação do solo de 1990 (COS'90). A análise efectuada reforçou a confiança nos resultados obtidos. As transições impossíveis ocorridas foram reduzidas e em grande parte motivadas pelo facto da área mínima do Mapa de Ocupação do Solo produzido ser inferior à área mínima da COS'90.

A metodologia adoptada poderá ser melhorada em diversos aspectos: por um lado no que diz respeito aos dados imagem utilizados na classificação, por outro, em termos metodológicos. No aspecto metodológico, existem algumas hipóteses que poderiam ser testadas com os dados imagem utilizados de modo a conseguir uma melhoria de precisão e que consistem no uso de um modelo de superfície (Hofmann 2001c) e de dados auxiliares como sejam, por exemplo, os dados estatísticos censitários (Rocha *et al.*, 2001), rede viária, etc.. O uso do modelo de superfície na fase de segmentação tem sido utilizado com sucesso por diversos autores na extracção de informação de áreas urbanas, permitindo criar objectos melhor adaptados à estrutura dos objectos reais e minimizar a confusão espectral entre áreas artificiais e não artificiais. O facto de se integrarem os dados auxiliares na análise das imagens, para além de auxiliar a classificação permitindo a sua utilização na construção de regras, permite também eliminar os problemas posteriores de integração dos dados .

Outra forma de minimizar a confusão espectral verificada no estudo entre Áreas residenciais, Áreas agrícolas e vegetação arbustiva consiste na utilização de imagens adquiridas em diferentes épocas do ano.

Outra possibilidade a testar seria utilizar a fusão dos dados imagem do satélite IKONOS (1m e 4m de resolução espacial no modo pancromático e multiespectral, respectivamente), à semelhança do trabalho realizado por Meinel *et al.* (2001), que demonstra que os limites das classes de cobertura do solo são melhor identificados com a imagem fusão do que usando apenas os dados multiespectrais ou pancromáticos.

Com a abordagem baseada em objectos obtiveram-se bons resultados contudo, é muito dependente da correcta construção das regras e funções de pertença. Este passo é muito moroso podendo ser minorado se as regras estabelecidas para uma determinada área podessem ser extrapoladas para outras áreas e outras imagens, sendo esta uma área de potencial investigação.

A fusão dos dados imagem dos novos satélites de grande resolução espacial, ao ser utilizada pelos vários serviços da Câmara Municipal da Marinha Grande, demonstrou estar bem adequada às necessidades em termos de informação urbana e às funções de planeamento dada a sua elevada resolução espacial.

Referências Bibliográficas

- Anderson, J.R., E.E. Hardy, J.T. Roach, e R.E. Witmer. 1976. A land use and land cover classification system for use with remote sensor data. Geological Survey Professional Paper 964, U.S. Government Printing Office, Washington, DC.
- Aplin, P., P. Atkinson, e P. Curran. 1999. Per-field classification of land use using the forthcoming very fine spatial resolution satellite sensors: problems and potential solutions. *Advances in Remote Sensing and GIS Analysis*. Edited by P. Atkinson, and N. Tate (Chichester: John Wiley and Sons): 219-239.
- Baatz, M., e A. Schape. 2000. Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation. In: Strobl, J. *et al.* (Hrsg.): *Angewandte Geographische Informationsverarbeitung XII. Beiträge Zum AGIT – Symposium Salzburg 2000*, Karlsruhe, Herbert Wichmann Verlag: 12-23.
- Baatz, M., M. Heynen, P. Hofmann, I. Lingenfelder, M. Mimler, A. Schape, M. Weber and Willhauck, G. 2000. «eCognition User Guide ». Definiens, AG. Munique.
- Baio, M. 1996. Avaliação de alterações de ocupação do solo por imagens numéricas multiespectrais. Tese de Mestrado, UNL/FCT, Lisboa.
- Barnsley, M.J., L.M.-Jensen, e S.L. Barr. 2001. Inferring urban land use by spatial and structural pattern recognition. *Remote Sensing and Urban Analysis*. Edited by J.- P. Donnay, M. Barnsley, P. Longley (New York: Taylor & Francis).
- Bauer, T., e K. Steinnocher. 2001. Per-parcel land use classification in urban areas applying a rule-based technique. *GeoBIT/GIS 6*: 12-17: 24-27.
- Beard, K. 1998. Detecting and evaluation errors by graphical methods, *NGGIA Core Curriculum in GIScience*. <http://negia.ucsb.edu/giscc/units/u099/u099>, posted June 23.
- Blaschke, T., S. Lang, E. Lorup, J. Strobl, e P. Zeil. 2000. Object-oriented image processing in an integrated sis/remote sensing environment and perspectives for environmental applications. Cremers, A. and Greve, k. (Hrsg.): *Environmental Information for Planning, Politics and the Public*. Metropolis Verlag, Marburg, Vol2: 555-570.
- Blaschke, T., e G. J. Hay. 2001. Object-oriented image analysis and scale-space: theory and methods for modeling and evaluation multiscale landscape structure. *International Archives of Photogrammetry and Remote Sensing*, vol.34, part 4/W5:22-29.
- Blaschke, T., e J. Strobl. 2001. What's wrong with pixels? Some recent developments interfacing remote sensing an GIS. *GeoBIT/GIS 6*:12-17.
- Burrough, P.A., e R. A. McDonnell. 1998. Principles of geographical information systems. Oxford University Press.
- Buttenfield, B. 1993. Representing data quality. *Cartographica*, 30 (2 e 3):1-7.

- Caetano, M. 1995. Burned vegetation mapping in mountainous areas with satellite remote sensing. Ma Thesis. University of California, Santa Barbara.
- Caetano, M. S., A Navarro, and J.P. Santos. 1997a. Improving urban areas mapping with satellite imagery by contextual and integration of a road network map. *Proceedings of the 23rd Annual Conference and Exhibition of the Remote Symposium (IGARSS'1997)*, Vol.I, 3 to 8 of August 1997, Singapore: 240-242.
- Caetano, M. S., A. Navarro, e J.P. Santos. 1997b. A multi-strategic approach for land use mapping of urban areas by integrating satellite and ancillary data. *Proceedings of the 1997 IEEE International Geoscience and Remote Sensing Symposium (IGARSS'1997)*, Vol.I, 3 to 8 of August 1997, Singapore: 240-242.
- Caetano, M. S., J. P. Santos, e A. Navarro. 1997c. Uma metodologia integrada para a produção de cartas de uso do solo utilizando imagens de satélite e informação georeferenciada não espectral. *Revista de Cartografia e Cadastro*, Nº 6 Instituto Português de Cartografia e Cadastro: 71-78.
- Caetano, M., F. Monteiro, e I. L. Ramos. 1999. «Monitoring urban dynamics: Portugal no contexto europeu». *ESIG'99*, V Encontro sobre Sistemas de Informação Geográfica
- Caetano, M. , T. Santos, H. Carrão, A Nunes, e M. Barreiros. 2001. Desenvolvimento de aplicações para generalização de cartografia temática. *ESIG'2001*, VI Encontro sobre Sistemas de Informação Geográfica.
- Carrão, H., Henriques, R., Nery, F., Caetano, M., 2001, MapGen – Automated Generalisation for Thematic Cartography, *Proceedings of 16th ESRI ENEA User Conference*. Em publicação.
- Campagnolo, M.L., e M. Caetano. 1997a. Expert maps: An alternative for integrating expert knowledge in satellite imagery classification. *Proceedings of the 1997 IEEE International Geoscience and Remote Sensing Symposium (IGARSS'1997)*, Vol. I, 3 to 8 of August 1997, Singapore,:680-682.
- Campagnolo, M. L., e M. Caetano.1997b. Abordagens multi-estratégicas para classificação de imagens de satélite. Relatório do projecto da DGOT/JNICT (28/94). Lisboa: CNIG publicações técnicas.
- Congalton, R. G., K. Green. 1999. Assessing the accuracy of remotely sense data: principles and practices. CRC Press, Inc.
- Couloigner, I., e T. Ranchin. 2000. Mapping of urban areas: a multiresolution modeling approach for semi-automatic extraction of streets. *Photogrammetric Engineering and Remote Sensing*, 66(7): 867-874.
- Crespo, R., L. Fonseca, H. Feith, A S. Macedo, J.L. Carvalho e L. Saldanha. 1999. Cartografia florestal do eucalipto, *ESIG'99*, V Encontro sobre Sistemas de Informação Geográfica.
- Chermant, J. L., e M. Coster. 1998. Précis d'analyse d'images. presses du CNRS, Paris.
- Cordeiro, A. G. 1996. Delineamento de objectos em teledeteção. Tese de Mestrado, IST/UTL, Lisboa.
- Demetre, A., e D. Panos.2002.Mapping urban green from IKONOS data by na object-

oriented knowledge-base and fuzzy logic. SPIE's Remote Sensing 23 to 27 September 2000, Crete. Greece.

- Destival, I. 1987. Recherche automatique de réseaux linéaires sur des images SPOT. Bulletin de la Société Française de Photogrammétrie et de Télédétection, 105:5-16.
- Donnay, J.-P., e L. Thomsin. 1994. Urban remote sensing and statistics: prospective research and application. *Proceedings of the Symposium: New Tools for Spatial Analysis*. Edited by M. Painlo; Eurostat (Luxembourg:Office for Official Publication of the European Communities): 137-145.
- Donnay, J.-P. 1999. Use of remote sensing information in planning. *Geographical Information and Planning*. Edited by J. Stillwell, S. Geertman and S. Openshaw , Berlin, Springer-Verlag: 242-260.
- Donnay, J.-P., M. Barnsley, e P. Longley. 2001. Remote sensing and urban analysis. *Remote Sensing and Urban Analysis*. Edited by J.- P. Donnay, M. Barnsley, P. Longley (New York: Taylor & Francis): 3-18.
- Dureau, F. 1990. Dossier sur la télédétection urbaine à 1ORSTOM, Technical Report 4, Villes et citadins du Tiers-Monde.
- Ehlers, M., e S. Wenzhong. 1996. Error Modelling for integrated GIS. *Cartographica*, 33 (1):11-21.
- Erivaldo, A. S. 1997. Extracções de feições cartográficas de imagens multiespectrais fundidas usando morfologia matemática. *Cartografia e Cadastro* N°6.
- Eurostat. 1993. *The Impact of Remote Sensing on the European Statistical System- Proceedings of the Seminar*, Bad Neuenahr (Luxembourg: office for Official Publication of the European Communities).
- Faiz, S., P. Boursier. 1994. Modeling and visualizing the quality of geographic information: an object-oriented approach. *Proceedings of European Gis'94*, Paris, France:161-168
- Fisher, P.F. 1993. Visualizing uncertainty in soil maps by animation. *Cartographica*, 30 (2 e 3):20-27
- Fisher, P.F. 1994. Visualizing the reliability in classified remotely sensed images. *Photogrammetric Engineering and Remote Sensing*, 60(7):905-910.
- Foody, G. 1995. Cross-entropy for the evaluation of the accuracy of a fuzzy land cover classification with fuzzy ground data, *ISPRS Journal of Photogrammetry and Remote Sensing*, 50(5):2-12.
- Foody, G. 1999. Image classification with a neural network: from completely-crisp to fully – fuzzy situations. *Advances in Remote Sensing and GIS Analysis*. Edited by P. Atkinson, and N. Tate (Chichester: John Wiley and Sons), pp.17-37.
- Fonseca, A. 1996. Melhoramento de uma classificação de ocupação do solo urbano utilizando informação textural. Conferência de Geodesia e Cartografia. Lisboa. Setembro, 1996.

- Fonseca, A. 1997. Melhoramento de uma classificação do solo urbano utilizando informação textural. *Revista do IPCC*. Dezembro. Lisboa.
- Fonseca, A. 1998. Análise quantitativa de imagens: utilização de imagens numéricas multiespectrais no controlo do desenvolvimento urbano, Dissertação. Edição Provisória. I & D Tese Barragens, LNEC, Lisboa.
- Franklin, S. E., e B. A. Wilson. 1992. A three-stage classifier for remote sensing of mountain environments. *Photogrammetric Engineering and Remote Sensing*, 58(4):449-454.
- Franklin, S. E., A.J. Maudie, e M.B. Lavigne. 2001. Using spatial co - occurrence texture to increase forest structure and species composition classification accuracy. *Photogrammetric Engineering and Remote Sensing*, 67(7):849-855.
- Freire, S. C., M. R. Caetano, e T.G. Santos. 2001. Cartografia da ocupação do solo com uma série multi-temporal intra-anual de imagens de satélite e informação auxiliar. ESIG´2001, VI Encontro sobre Sistemas de Informação Geográfica.
- Friedl, M. A., e C. E. Brodley. 1997. Decision tree classification of land cover from remote sensed data. *Remote Sensing of Environment*, 61:399-409.
- Geoterra. 1997. Estudo das causas dos incêndios com vista à sua prevenção no Concelho da Marinha Grande. CMMG.
- Gong, P., e P. Howarth. 1992. "Frequency-based contextual classification and gray-level vector reduction for land-use identification," *Photogrammetric Engineering and Remote Sensing*, 58(4):423-437.
- Gonçalves, L., A. Fonseca, e M. Caetano. 2001. Exploração de imagens de alta resolução do satélite IKONOS. ESIG´2001, VI Encontro sobre Sistemas de Informação Geográfica.
- Gonzalez, R. C., e R. E. Woods. 1992. *Digital Image processing*, Addison Wesley Publishing Company.
- Heyman. (data de acesso 18-09-2002). Automatic extraction of Natural objects from 1-m remote sensing images. <http://www.cbblestoneconcepts.com/ucgis2summer/heyman/heyman.htm>.
- Hinton, J.C. 1999. Image classification and analysis using integrated GIS, In: *Advances in Remote Sensing and GIS Analysis*. Edited by P. Atkinson, and N. Tate (Chichester: John Wiley and Sons): 167-184.
- Hofmann, P. 2001a. Detecting informal settlements from IKONOS image data using methods of object oriented image analysis – an example from Cape Town (South Africa). Edited by C. Jürgens. *Remote Sensing of Urban Areas*. Regensburg:41-42.
- Hofmann, P. 2001b. Detecting urban features from IKONOS data using an object-oriented approach. *Remote Sensing and Photogrammetry Society* (Editor). *Proceedings of the First Annual Conference of Remote Sensing and Photogrammetry Society*, 12-14 September 2001: 28-33.
- Hofmann, P. 2001c. Detecting Builds and Roads from IKONOS Image Data Using Additional Elevation Information. *Geobits/Gis* 6: 28-33.

- Howard, V. 1998. Data quality measurement and assessment, *NGGIA Core Curriculum in GIScience*. <http://negia.ucsb.edu/giscc/units/u100/u100.html>, posted March 23.
- Hunter, G.J., e M.F. Goodchild. 1995. Dealing with error in spatial databases: a simple case study. *Photogrammetric Engineering and Remote Sensing*,. 61: 529-37.
- Hutchinson, C.F. 1982. Techniques for combining Landsat and ancillary data for digital classification improvement. *Photogrammetric Engineering and Remote Sensing*, 48(1): 123-130.
- Janssen, L., M. Jaarsma,. e E. van der Linden. 1990. Integrating topographic data with remote sensing for land cover classification, *Photogrammetric Engineering and Remote Sensing*,56:1503-1506.
- Jensen, J. R., e D.L. Toll. 1982. Detecting residential land-use development at the urban fringe. *Photogrammetric Engineering and Remote Sensing*, 48 (4): 629-643.
- Jensen, J. R. 1986. *Introductory Digital Image Processing*. Prentice – Hall. New Jersey.
- Jensen, J. R. 1996. *Introductory Digital Image Processing*. Prentice – Hall. New Jersey.
- Jones, A.R., J.J. Settle, e B. K. Wyatt. 1988. “Use of Digital Terrain Data in the Interpretation of SPOT-1 HRV Multispectral Imagery“. *International Journal of Remote Sensing*, 9(4):669-682.
- Kaufman, Y. J. 1984. Atmospheric effects on remote sensing of surface reflectance. *Proceedings of the SPIE International Society for Optical Engineering.*, 20-33. Seattle, Washington.
- Kontoes, C.C. e D. Rokos. 1996. The integration of spatial context information in an experimental knowledge-based system and the supervised relaxation algorithm: Two successful approaches to improving SPOT XZ classification. *International Journal of Remote Sensing*, 16:3093-3106.
- Leitner, M., e B. Buttenfield. 2000. *Cartography and Geographic Information Science*, 27 (1):3-14.
- Lillesand, T. M., e R. W. Kiefer. 1994. *Remote Sensing and Image Interpretation*. John Wiley and Son, Inc.. New York.
- Lillesand, T. M., e R. W. Kiefer. 2000. *Remote Sensing and Image Interpretation*, John Wiley and Son, Inc.. New York.
- Lantuéjoul, C. e S. Beucher. 1979. On the use of Geodesic metric in image analysis. *Journal of Microscopy*, 121:29-49
- Lo, C.P. 1995. Automated population and dwelling unit estimation for high resolution satellite imagery: A GIS approach. *International Journal of Remote Sensing*, 16:17-34.
- Lobo, A. 1997. Image segmentation and discrimination analysis for the identification of land cover units in ecology, *IEEE Transactions on Geoscience and Remote Sensing*, 35:1136-1145.

- MacEachren, A.M., D. Howard, von M. Wyss, D. Askov, e T. Taormino. 1993. Visualisation the health of Chesapeake bay: an uncertain endeavour. *Proceedings GIS/LIS 93 Minneapolis*: 449-58.
- MacEachren, A.M. 1994. Some truth with maps: a primer on symbolisation and design. Washington DC, American Association of Geographers.
- Marques, J.S. 1999. Reconhecimento de padrões métodos estatísticos e neuronais, IST Press.
- Mason, D.C., D. G. Corr, A. Cross, D. C. Hoggs, D. Lawrence, M. Petrou, e A.M. Taylor. 1988. The Use of Digital Map Data in the Segmentation and Classification of Remotely Sensed Data, *International Journal of Geographical Information System*,2(3):195-215.
- Meinel, G., M. Neubert, e J. Reder. 2001. The Potential Use of Very High Resolution Satellite Data for Urban Areas – First Experiences with IKONOS Data, Their Classification and Application in Urban Planning and Environmental Monitoring. Vortrag auf dem 2end Syposium Remote Sensing of Urban Areas. Regensburg – Regensburger Geographische Schriften 37:67-68.
- Mesev, V., e P.A. Longley. 1999. The Rôle of Classification Imagery in Urban Spatial Analysis. *Advances in Remote Sensing and GIS Analysis*. Edited by P. Atkinson, and N. Tate (Chichester: John Wiley and Sons): 185-206.
- Mid-Atlantic RESAC. (data de acesso 18-09-2002). Using Ikonos satellite imagery to map riparian forest buffers. <http://www.geog.umd.edu/resac/riparian.htm>.
- Mitasova, H., L. Mitas, W. Brown, D. P. Gerdes, I. Kosinovsky, e T. Baker. 1995. Modelling spatial and temporally distributed phenomena: new methods and tools for GRASS GIS. *International Journal of Geographical Information System*, 9: 433-46.
- Moller-Jensen L. 1990. Knowledge-based classification of an urban area using texture and context information in Landsat-TM imagery. *Photogrammetric Engineering and Remote Sensing*, 56: 899-904.
- Muge, F., e P. Pina. 1998. Segmentation by Watershed. Universidade Técnica de Lisboa. Instituto Superior Técnico, CVRM.
- Muge, F., e F. Soares. 1998. Morphological image processing for cartography. *Cartografia e Cadastro* N°9.
- Navarro, A. 1999. Cartografia de áreas urbanas com base em dados de detecção remota. Tese de Mestrado, IST/UTL, Lisboa.
- Neto, F. A. 1997. Projecto de um sistema automático de integração de imagens e dados cartográficos na detecção de alterações da superfície terrestre. *Cartografia e Cadastro* N°6.
- Nunes, A., M. Caetano e T. Santos. 2002. Rule based generalisation of satellite derived raster thematic maps. *Proceedings of the 9th International Symposium on Remote Sensing (SPIE)*, Crete, September 2002.
- Paradis, J., e K. Beard. 1994. Visualisation of data quality for the decision-maker: a data

- quality filter. *Journal of the Urban and Regional Information Systems Association* 6:25-34.
- Pedley, M.I., e P.J. Curran, 1991. Per-field classification: an example using SPOT HRV imagery. *International Journal of Remote Sensing*,12(11):2181-2192.
- Perry, C.R., e L.F. Lautenschlager. 1984. Functional equivalence of spectral, *Remote Sensing of Environment*, vol.14.
- Pesaresi, M., e A. Bianchin. 2001. Inferring urban land use by spatial and structural pattern recognition. *Remote Sensing and Urban Analysis*. Edited by J.- P. Donnay, M. Barnsley, P. Longley (New York: Taylor & Francis).
- Pina, P. M. B. D. 1998. Caracterização, modelação e simulação de estruturas com base na morfologia matemática. Tese de Doutoramento, IST/ UTL, Lisboa.
- Portugal, J. M. 1992. Introdução às tecnologias de levantamento de informação. Lisboa, Edição do Autor.
- Power, C., A. Simms, e R. White. 2001. Hierarchical fuzzy pattern matching for the regional comparison of land use maps. *International Journal Geographical Information Science*, 2001, 15 (1): 77-100.
- Pina, P. M. B. D. 1992. Análise de imagem e morfologia matemática na caracterização de recursos naturais. Tese de Mestrado, IST/ UTL, Lisboa.
- Richards, J. A. 1986. *Remote Sensing Digital Image Analysis*. Berlim, Germany: Springer-Verlag.
- Richards, A. e J. Xiuping. 1999. *Remote Sensing Digital Image Analysis – An Introduction*. Springer-Verlag Berlin Heidelberg. New York.
- Rocha, J., M. P. Queluz, e J. A. Tenedório. 2001. Integração de dados estatísticos na classificação de imagens de satélite (IDECIS). ESIG'2001, VI Encontro sobre Sistemas de Informação Geográfica.
- Russ, J.C. 1994. *The Image Processing Handbook*, 2nd edition. CRC Press.
- Sá, A.C.L. 1999. Comparação entre a Regressão Logística e as Árvores de Classificação na Cartografia de Áreas Áridas com Imagens do Satélite Landsat 5 TM. Tese de Mestrado, ISA/UTL, Lisboa.
- Santos, J.P., M.S. Caetano e A. Navarro.1996. Integração de informação contextual na identificação de classes de uso do solo em dados de imagens de satélite. *Comunicação apresentada na Conferência de Cartografia e Geodesia*. Faculdade de Ciências da Universidade de Lisboa, 26 e 27 de Setembro de 1996.
- Schiewe, J., L. Tufte, e M. Ehlers. 2001. Potential and Problems of Multi-scale Segmentation Methods in remote Sensing. *GeoBIT/GIS*, 6: 34-39.
- Serendo, M.A. 1989. Extraction d'information symboliques en imagerie SPOT: réseaux de communications et agglomérations. Ph. D thesis of the University of Nice.
- Serra, J. 1994. *Image Analysis and Mathematical Morphology*, volume 1. Academic Press.

- Serra, J. 1988. *Image Analysis and Mathematical Morphology*, volume 2: Theoretical Advances. Academic Press.
- Serra, J. e P. Soille. 1994. *Mathematical Morphology and Its Applications to Image Processing*. Kluwer Academic Publishers.
- Silva, J. M. N. 1999. *Aplicação de técnicas de estatística multivariada à cartografia de áreas áridas com imagens do satélite Landsat 5 TM*. Tese de Mestrado, ISA/UTL, Lisboa.
- Silva, S. e M. Caetano. 1996. Using artificial recurrent neuronal nets to identify spectral and spatial patterns for satellite imagery classification of urban areas. *Proceedings of the Workshop on Methods for Preprocessing and Analysis of Remote Sensing (COMPARES)*, University of York, 17 to 19 of July 1996.
- Soares, F. 1998. *Processamento morfológico de imagem para cartografia*. Tese de Mestrado, IST/ UTL, Lisboa.
- Sousa, A., J. Silva, e J. Pereira. 1997. Cartografia de áreas áridas em Portugal com imagens Landsat 5 TM. *Revista Florestal*, Vol. X, nº1.
- St-Onge, B.A., e F. Cavayas. 1997. Automated forest structure mapping from high resolution imagery based on directional semivariogram estimates, *Remote Sensing of Environment*, 61: 82-95.
- Teillet, P. M. 1986. Image correction for radiometric effects in remote sensing. *International Journal of Remote Sensing* 7: 1637- 1651.
- Teodoro, A. C. e M. J. Fernandes 2000. Estudo do crescimento urbano da Área Metropolitana do Porto (AMP) usando técnicas de detecção remota. *Ingenium*, 2ª Série, Nº 56, Março 2001: 63-67.
- Totter, C.M. 1991. Remotely-sensed data as an information source for geographical information system in natural resource management. *International Journal of Geographical Information Systems*, 5(2):225-239.
- Wang, F. 1990. Improving remote sensing image analysis through fuzzy information representation, *Photogrammetric Engineering and Remote Sensing*, 56 (8):1163-1169.
- Wang, D., D.C. He, L. Wang, e D. Morin. 1996. L'extraction du réseau routier urbain à partir d' images SPOT HRV, *International Journal of Geographical and Remote Sensing*, 17(4):827-833.
- Wenzhong, S., M. Ehlers, e K. Tempfli. 1994. Modeling and visualizing uncertainties in multi-data-based spatial analysis. *Proceedings of European Gis'94*, 454-464. Paris, France.
- Wilkinson, G.G. 1996. A review of current issues in the integration of GIS and remote sensing data. *International Journal of Geographical and Remote Sensing*, 10: 85-101.
- Zadeh, L. 1965. Fuzzy Sets. *International and Control*, 8:338-353.

ANEXOS

ANEXO 1 – Nomenclatura de referência

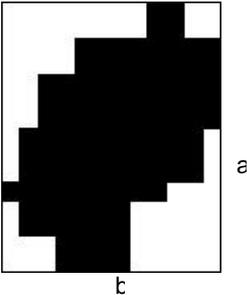
NIVEL I	NIVEL II	NIVEL III	NIVEL IV	
1 Áreas artificiais	11 Zonas com dominância de habitação	111 Áreas residenciais	1111 Áreas residenciais contínuas	
			1112 Áreas residenciais descontínuas	
		112 Serviços de utilidade pública e administração local		
	12 Zonas com revestimento predominantemente artificializado	121 Espaços de actividades industriais, comerciais e equipamentos gerais	1211 Zonas industriais	1212 Zonas comerciais e financeiras
		122 Infra-estruturas da rede viária e da rede ferroviária	1221 Rede viária	1222 Rede ferroviária
	13 Zonas alteradas artificialmente sem vegetação	131 Pedreiras, saibreiras		
		132 Descargas industriais e zonas de lixeiras e depósitos de sucata		
		133 Estaleiros		
		134 Etar		
	14 Zonas verdes ordenadas	141 Espaços verdes urbanos		
		142 Infra-estruturas desportivas		
143 Zonas históricas e espaços culturais				
2 Áreas com ocupação agrícola	21 Zonas agrícolas com culturas anuais			
	22 Culturas permanentes			
	23 Pastagens			
	24 Zonas agrícolas heterogéneas			
3 Floresta	31 Folhosas			
	32 Resinosas			
	33 Povoamento florestal misto			
4 Meios semi-naturais	41 Zonas com vegetação arbustiva e herbácea			
	42 Zonas naturais com ou sem pouca vegetação	421 Praias, dunas areais, solos sem cobertura vegetal		
		422 Rochas nuas		
		423 Zonas incendiadas recentemente		
43 Áreas corte floresta				
5 Meios aquáticos	51 Zonas húmidas continentais			
	52 Zonas húmidas marítimas			
6 Superfícies com água	61 Zonas de água doce			
	62 Zonas de água salgada			

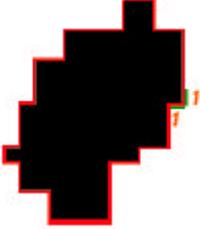
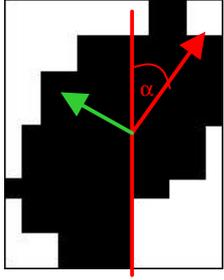
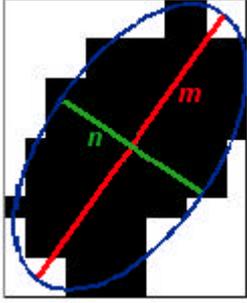
ANEXO 2 – Atributos utilizados na classificação

Atributos		Formula/Ilustração	Descrição
Atributos espectrais			
Média	Média	$(1) \overline{C}_L = \frac{1}{n} \cdot \sum_{i=1}^n C_{Li}$	O valor médio espectral \overline{C}_L de cada objecto na banda L é a média dos valores espectrais C_{Li} de todos os n <i>pixels</i> que constituem o objecto imagem na banda L.
	Brilho	$(2) b = \frac{1}{n_L} \cdot \sum_{i=1}^{n_L} \overline{C}_i$	É o somatório de todos os valores médios espectrais de cada objecto obtidos em cada uma das bandas a dividir pelo numero de bandas (é a média dos valores médios espectrais de um objecto imagem)
Desvio Padrão	Desvio Padrão	$(3) s_L = \sqrt{\frac{1}{n-1} \cdot \sum_{i=1}^n (C_{Li} - \overline{C}_L)^2}$	Calculado a partir de todos os n <i>pixels</i> que formam um objecto
Quociente	Quociente	$(4) r_L = \frac{\overline{C}_L}{\sum_{i=1}^{n_L} \overline{C}_i}$	É o quociente entre o valor médio espectral de cada objecto numa dada banda L e o somatório dos valores médios espectrais de todas as bandas.
Vizinhos	Diferença média entre vizinhos	$(5) \Delta C_L = \frac{1}{l} \cdot \sum_{i=1}^n l_{Si} \cdot (\overline{C}_L - \overline{C}_{Li})$ $(6) \Delta C_L = \frac{1}{A} \cdot \sum_{i=1}^n A_i \cdot (\overline{C}_L - \overline{C}_{Li})$ <p>l - perímetro do objecto imagem</p> <p>l_{Si} - comprimento dos limites partilhados com o vizinho directo i</p> <p>\overline{C}_L - valor médio do objecto imagem na banda L</p> <p>\overline{C}_{Li} - valor médio do objecto imagem vizinho i</p> <p>n - número de vizinhos</p> <p>A - área total coberta pelos objectos vizinhos</p> <p>A_i - área coberta pelo objecto vizinho i</p> <p>n - nº de objectos vizinhos</p>	Pode ser calculada de duas maneiras: relativamente ao comprimento dos limites entre os objectos (se forem vizinhos directos distância=0) expressão (5) ou relativamente à área coberta pelos objectos vizinhos através expressão (6) (se a vizinhança é definida num certo perímetro (em <i>pixels</i>) em torno do objecto imagem em questão, distância>0).
	Diferença média entre vizinhos em valor absoluto	$(7) \Delta C_L = \frac{1}{l} \cdot \sum_{i=1}^n l_{Si} \cdot \overline{C}_L - \overline{C}_{Li} $ $(8) \Delta C_L = \frac{1}{A} \cdot \sum_{i=1}^n A_i \cdot \overline{C}_L - \overline{C}_{Li} $	Idêntica à definição da Diferença média entre vizinhos, só que a Diferença média entre objectos vizinhos é em valor absoluto.

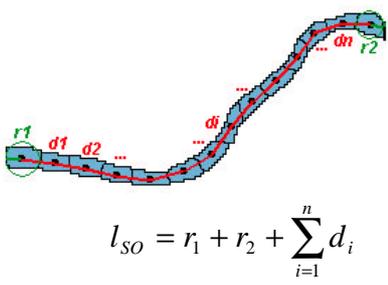
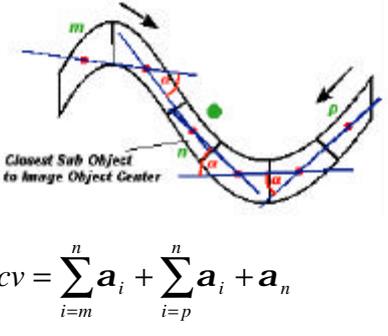
Diferença média entre os vizinhos brilhantes		Este atributo é calculado da mesma forma que a Diferença média entre os objectos vizinhos, mas apenas são visualizados os objectos imagem com um valor médio maior que o valor médio de um determinado objecto considerado.
Diferença média entre os vizinhos escuros		Este atributo é calculado da mesma forma que a Diferença média entre os objectos vizinhos, mas apenas são visualizados os objectos imagem com um valor médio menor que o valor médio de um determinado objecto.
Limites relacionados com vizinhos brilhantes.		Quociente entre o comprimento do limite partilhado com os objectos imagem com valor médio elevado e o comprimento total do objecto imagem em causa.

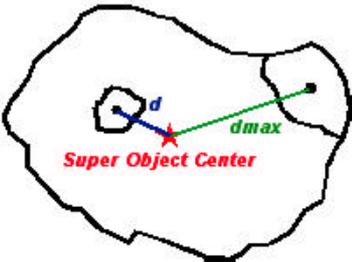
Forma

Área		Com dados não georeferenciados a área de um pixel é 1. Consequentemente, a área de um objecto imagem é o número de pixels que o formam. Se os dados imagem estão georeferenciados, a área de um objecto imagem é a verdadeira área coberta pelo pixel vezes o número de pixels que forma o objecto imagem.
Comprimento/ Largura	$(12) \mathbf{g} = \frac{l}{w} = \frac{eig_1(S)}{eig_2(S)},$ $eig_1(S) > eig_2(S)$ $(13) \mathbf{g} = \frac{l}{w} = \frac{a^2 + ((1-f) \cdot b)^2}{A}$ <p> <i>a</i> - comprimento da caixa envolvente <i>b</i> - largura da caixa envolvente $f = \frac{A}{a \cdot b}$ <i>A</i> – área do objecto imagem </p> 	<p>O quociente comprimento largura pode ser calculado de duas maneiras:</p> <p>(1) através do quociente entre os valores próprios (<i>eigenvalues</i>) da matriz covariância em que o maior valor próprio é o numerador (expressão (12)).</p> <p>(2) usando a caixa envolvente (expressão (13)).</p> <p>O eCognition usa os dois métodos e utiliza o menor dos dois resultados.</p>

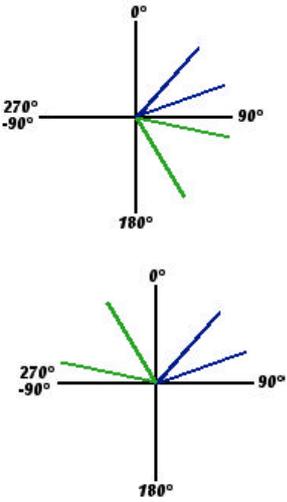
	Comprimento	(14) $l = \sqrt{A \cdot g}$	O comprimento é calculado usando o quociente comprimento/largura relativamente à caixa envolvente
	Largura	(15) $w = \sqrt{\frac{A}{g}}$	A largura é uma aproximação usando o quociente do comprimento/largura
	Perímetro		O perímetro de um objecto imagem é definido como a soma dos comprimentos dos lados dos <i>pixels</i> que fazem parte do objecto e que são partilhados com outro objecto imagem ou estão situados no limite da imagem. Numa imagem não georeferenciada o comprimento dos lados do <i>pixel</i> é 1.
	Índice da forma	(16) $s = \frac{e}{4 \cdot \sqrt{A}}$ e- perímetro	O índice da forma é obtido dividindo o perímetro de um objecto imagem dividido por quatro vezes a raiz da sua área. É usado para descrever a suavização dos limites dos objectos imagem.
	Densidade	$d = \frac{\sqrt{n}}{1 + \sqrt{\text{Var}(X) + \text{Var}(y)}}$ n- nº de <i>pixels</i> que formam o objecto imagem	A densidade <i>d</i> pode ser expressa pela área abrangida pelo objecto imagem dividida pelo seu raio. No eCognition o raio é determinado usando a matriz de covariância.
	Direcção Principal		No eCognition, a direcção principal de um objecto imagem é a direcção do vector próprio (eigenvector) pertencendo ao maior dos dois valores próprios derivados a partir da matriz covariância da distribuição espacial do objecto imagem
	Assimetria	 $k = 1 - \frac{n}{m}$	Quanto mais comprido um objecto imagem, mais assimétrico ele será. Uma aproximação a um objecto imagem será uma elipse. A assimetria pode ser expressa pelo quociente dos comprimentos menor e maior dos eixos desta elipse. O valor característico será incrementado com a assimetria.

Características lineares baseadas em Sub-objectos

<p>Comprimento</p>	 $l_{SO} = r_1 + r_2 + \sum_{i=1}^n d_i$	
<p>Largura</p>	$w_{SO} = \frac{A}{l_{SO}}$	<p>A largura do objecto imagem calculada com base nos sub-objectos é a área A (em pixels) do objecto imagem dividida pelo seu comprimento derivado da análise dos sub-objectos</p>
<p>Comprimento da Curvatura</p>	 $CV = \sum_{i=m}^n a_i + \sum_{i=p}^n a_i + a_n$	<p>A curvatura de um objecto imagem dividida pelo seu comprimento. Tanto a curvatura como o comprimento são baseados na análise dos sub-objectos. A curvatura é a soma de todas as mudanças de direcção (valores absolutos) através da iteração dos sub-objectos a partir de ambos os extremos para o sub-objecto situado mais perto do centro do objecto imagem em estudo</p>
<p>Desvio Padrão da Curvatura</p>		<p>O desvio padrão de todas as mudanças de direcção quando se processa a iteração através dos extremos dos sub-objectos para o sub-objecto, o qual está situado perto do centro do objecto imagem em estudo. Se um objecto imagem pode ser caracterizado por um grande desvio padrão da sua curvatura, isto significa que existe um grande número de mudanças na direcção quando se itera através dos sub-objectos. Por outro lado, um objecto imagem pode aparecer curvo mas se segue uma linha circular, o desvio padrão da sua curvatura será pequeno uma vez que as mudanças de direcção, quando se itera através dos sub-objectos, são mais ou menos constantes</p>

Posição	X - Centro		Posição X do centro do objecto imagem (centro de gravidade, valor médio de todas as coordenadas X)
	Y - Centro		Posição Y do centro do objecto imagem (centro de gravidade, valor médio de todas as coordenadas Y)
	X -Mínimo		Posição X-Mínimo do objecto imagem (derivada da caixa envolvente)
	Y - Mínimo		Posição Y-Mínimo do objecto imagem (derivada da caixa envolvente)
	X - Máximo		Posição X-Máximo do objecto imagem (derivada da caixa envolvente)
	Y - Máximo		Posição Y-Máximo do objecto imagem (derivada da caixa envolvente)
Em relação aos Super-Objectos	Limites internos relativos ao super-objecto		Este valor é calculado dividindo a soma da margem partilhada com outros objectos imagem que têm o mesmo super-objecto pela margem total do objecto imagem. Se a margem interna relativa ao super-objecto é 1, o objecto imagem em questão não está situado na margem do seu super-objecto. Este valor serve para quantificar quanto um objecto imagem está situado na margem do seu super-objecto
	Área relativamente ao super-objecto		O valor é calculado dividindo a área do objecto imagem em questão pela área coberta pelo seu super-objecto. Se o valor característico é 1, então o objecto imagem é idêntico ao seu super-objecto. Este valor serve para descrever um objecto imagem pela quantidade de área que cobre do seu super-objecto
	Posição radial relativa ao super-objecto		O valor é calculado dividindo a distância entre o centro do objecto imagem em causa e o centro do seu super-objecto pela distância do centro do objecto imagem mais distante que tem o mesmo super-objecto

Textura			
Textura baseada no valores espectrais dos sub-objectos(SO)	Média de SO: Desvio Padrão		Desvio padrão dos diferentes valores médios da banda dos sub-objectos. Em primeiro lugar este valor pode parecer muito similar ao desvio padrão simples calculado a partir dos valores dos pixels simples (valores característicos), mas pode ter maior significado uma vez que o desvio padrão é calculado sobre áreas homogéneas e significantes. Quanto mais pequenos os sub-objectos mais o valor característico se aproxima do desvio padrão calculado a partir de pixels simples
	Diferença Média entre objectos vizinhos		Contraste no interior de um objecto imagem expresso pela média da diferença média de todos os seus sub-objectos para uma banda específica. Este valor tem uma certa referência espacial, descrita como contraste local no interior da área coberta pelo objecto imagem. Para cada simples sub-objecto, a banda diferença média L (valores absolutos) é calculada para sub-objectos adjacentes do mesmo super-objecto. O valor característico é o valor médio da banda diferença média L
Textura baseada na forma dos sub-objectos(SO)	Área de SO: Média		Valor médio das áreas dos sub-objectos
	Área de SO: Desvio Padrão		Desvio padrão das áreas dos sub-objectos
	Densidade de SO: Média		Valor médio calculado a partir das densidades dos sub-objectos
	Densidade de SO: Desvio Padrão		Desvio padrão calculado a partir das densidades dos sub-objectos
	Assimetria de SO: Média		Valor médio das assimetrias dos sub-objectos
	Assimetria de SO: Desvio Padrão		Desvio padrão das assimetrias dos sub-objectos

	Direcção de SO: Média		Valor médio das direcções dos sub-objects. No cálculo, as direcções são medidas através da assimetria do respectivo sub-objecto (quanto mais assimétrico um objecto imagem, mais significativa será a sua direcção principal). Antes do cálculo do valor característico actual, o algoritmo compara a variância de todas as direcções principais com a variância das direcções principais dos sub-objects, onde todas as direcções entre 90° e 180° são invertidas (direcção – 180°). O conjunto de direcções principais, as quais têm a menor variância, é seleccionado para o cálculo do valor médio da direcção principal medida pelas assimetrias do sub-objecto
	Direcção de SO: Desvio Padrão		Desvio padrão das direcções dos sub-objects. Novamente, as direcções principais são medidas pelas assimetrias dos respectivos sub-objects. O conjunto das direcções principais dos sub-objects nas quais é calculado o desvio padrão é determinado do mesmo modo como acima referido (Direcção de SO : Média)
Hierarquia			
	Nível		O número do nível do objecto imagem na qual o objecto imagem está situado. Será necessário este valor, se for feita a classificação em diferentes níveis de objectos imagem para definir qual a descrição da classe que é válida para cada um dos níveis
	Número de níveis superiores		Número de níveis de objectos imagem situados acima do nível do objecto imagem em questão. É idêntico ao número de super-objects que um objecto imagem poderá ter.

Número de níveis inferiores		Número de níveis de objectos imagem situados abaixo do nível do objecto imagem em consideração
Número de Vizinhos		Número de vizinhos directos de um objecto imagem (i.e. vizinhos com os quais tem uma fronteira comum) no mesmo nível da Hierarquia dos Objectos Imagem
Número de sub objectos		Número de sub-objectos de um objecto imagem no próximo nível inferior na Hierarquia dos Objectos Imagem

ANEXO 3 – Estrutura padrão de conteúdos do modelo geográfico de âmbito municipal

ESTRUTURA PADRÃO DE CONTEÚDOS DO MODELO GEOGRÁFICO DE ÂMBITO MUNICIPAL

Administração Local	Serviços Públicos	Segurança Pública
Câmara Municipal Assembleia Municipal Serviços da Câmara Municipal Juntas de Freguesia	Repartições de Finanças Cartórios Notariais Tribunais Finanças	Polícia de Segurança Pública Guarda Nacional Republicana

Serviços Úteis	Serviços Sociais	Protecção Civil
Conservatórias Correios Mercados/lotas	Centros de Dia Centros de Emprego e Formação Profissional Santa Casa da Misericórdia	Bombeiros Protecção Civil

Ensino	Desporto	Saúde
Ensino Pré-Escolar Ensino Básico Ensino Secundário Ensino Superior	Complexos Desportivos Campos de Ténis Grandes Campos Pequenos Campos Instalações Especiais Piscinas Salas de Desporto Pavilhões	Centros de Saúde Unidades de Saúde Farmácias Clínicas Consultórios Laboratórios Ervanárias Clínicas Veterinárias

Espaços Verdes	Higiene Urbana e Resíduos Sólidos	Saneamento Básico
Parques Jardins Equipamentos	Ecopontos, Contentores, Moloks Circuitos de Recolha Selectiva	Rede de Abastecimento de Águas ETAR

Património	Cultura	Religião
Imóveis Classificados Zona de Protecção Imóveis não Classificados	Bibliotecas Cinemas e Teatros Museus Monumentos Colectividades Culturais/Recreativas	Igrejas Capelas Cemitérios

Actividades Económicas	Turismo e Lazer
Indústria Comércio Serviços	Postos de Turismo Alojamento Animação Nocturna Roteiros Praias

Vias de Comunicação	Transporte	Mobiliário urbano
Rede viária e Toponímia Rede ferroviária	Terminais Rodoviários Terminais Ferroviários Postos de Abastecimento de Combustível Parques de Estacionamento Praças de Táxis	Bancos Papeleiras Floreiras Luminárias Semáforos Sinalização Horizontal e Vertical Balizadores Caldeiras Suportes bicicletas

Mapas	Gestão Urbanística	Físicos
Cartografia de Base	Plano Director Municipal	Carta de Ocupação do Solo

Estatísticos	Políticos	Limites Administrativos
Indicadores do Concelho e Freguesia (Instituto Nacional de Estatística (INE))		Concelho Freguesia Aglomerados Urbanos

ANEXO 4 – Estruturação da informação auxiliar num sistema de informação geográfica.

Equipamento escolar

A base de dados relativa ao Equipamento escolar envolve um conjunto de quatro tabelas designadamente: Equipamentos, Limite propriedade, Atributos e Ponto conforme apresentado no quadro A4.1. Na figura A4.1 são apresentadas as relações do modelo de dados do Equipamento escolar. A figura A4.2 exemplifica uma área da imagem onde foram identificados os edifícios escolares e os limites de propriedade.

Quadro A4.1 – Categorias, Tabelas geográficas, Geometria e Tabelas alfanuméricas do Equipamento escolar.

Categoria	Tabelas geográficas	Geometria	Tabelas alfanuméricas
	Ponto	Ponto	Atributos
Equipamento escolar	Limite propriedade	Área	
	Equipamentos	Área	

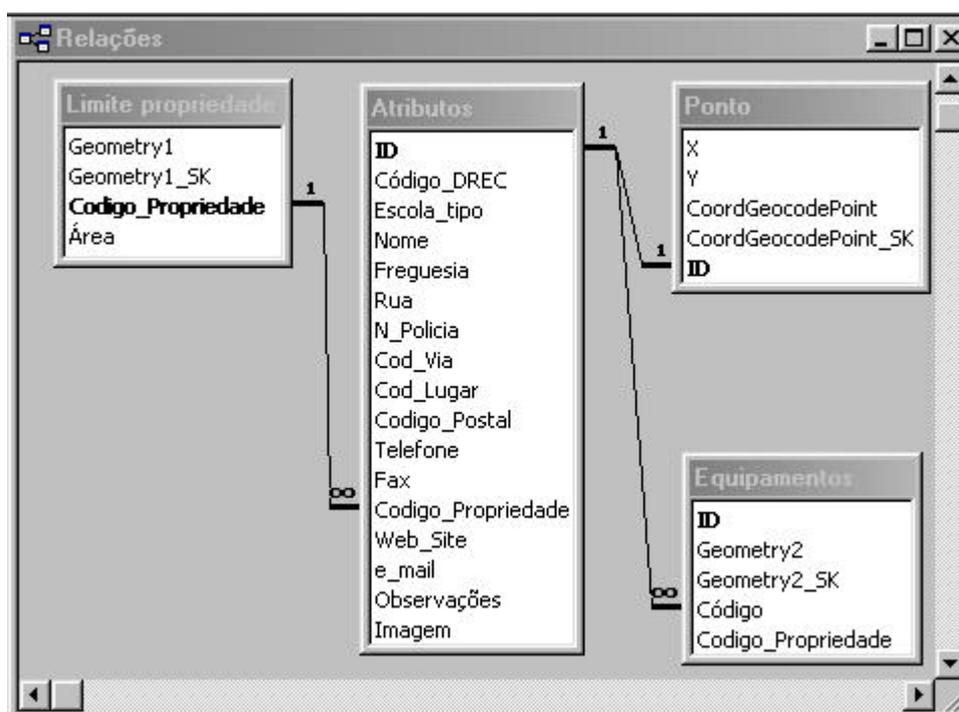


Figura A4.1 – Relações do modelo de dados do Equipamento escolar.

A entidade ponto foi criada apenas para se poder associar um símbolo relativo ao tipo de ensino se eventualmente se pretendesse efectuar um mapa temático do equipamento escolar a uma escala menor como, por exemplo, 1:50 000.

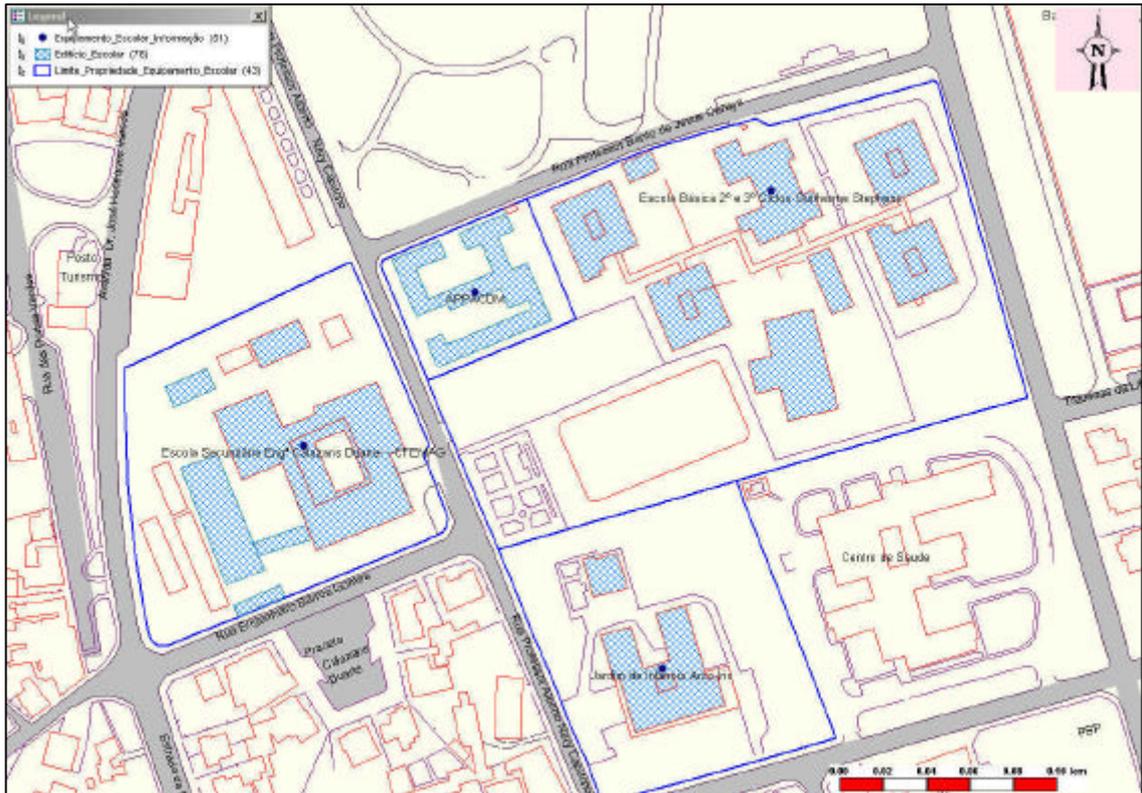


Figura A4.2 – Edifícios e limites de propriedade do Equipamento escolar. Os edifícios escolares estão identificados com uma trama azul, os limites de propriedade com traço contínuo azul e o ponto a azul escuro (centróide).

Equipamento desportivo

A base de dados relativa ao Equipamento desportivo possui 25 tabelas que pretendem representar: Complexos desportivos, Campos de ténis, Grandes campos, Pequenos campos, Pavilhões, Instalações especiais, Piscinas e Salas de desporto e que são apresentadas no quadro A4.2. Na figura A4.3 são ilustradas as relações do modelo de dados das Infra-estruturas desportivas.

A entidade ponto desporto foi criada também para se poder associar um símbolo relativo ao tipo de desporto se eventualmente se pretendesse efectuar um mapa temático do equipamento desportivo a uma escala menor conforme acima referido.

Quadro A4.2 – Categorias, Tabelas geográficas, Geometria e Tabelas alfanuméricas do Equipamento desportivo.

Categorias	Tabelas geográficas (Features)	Geometria	Tabelas alfanuméricas
Equipamento desportivo	Complexo desportivo propriedade	Área	Complexo atributos
	Complexo desportivo área		Equipamentos complexo atributos
	Complexo ponto	Ponto	
	Campos de ténis área	Área	Campos de ténis atributos
	Campos de ténis ponto	Ponto	
	Grandes campos área	Área	Grandes campos atributos
	Grandes campos ponto	Ponto	
	Pequenos campos área	Área	Pequenos campos atributos
	Pequenos campos ponto	Ponto	
	Instalações especiais área	Área	Instalações especiais atributos
	Instalações especiais ponto	Ponto	
	Piscinas área	Área	Piscinas atributos
	Piscinas ponto	Ponto	
	Salas de desporto área	Área	Salas de desporto atributos
Salas de desporto ponto	Ponto		
Pavilhões área	Área	Pavilhões atributos	
Pavilhões ponto	Ponto		

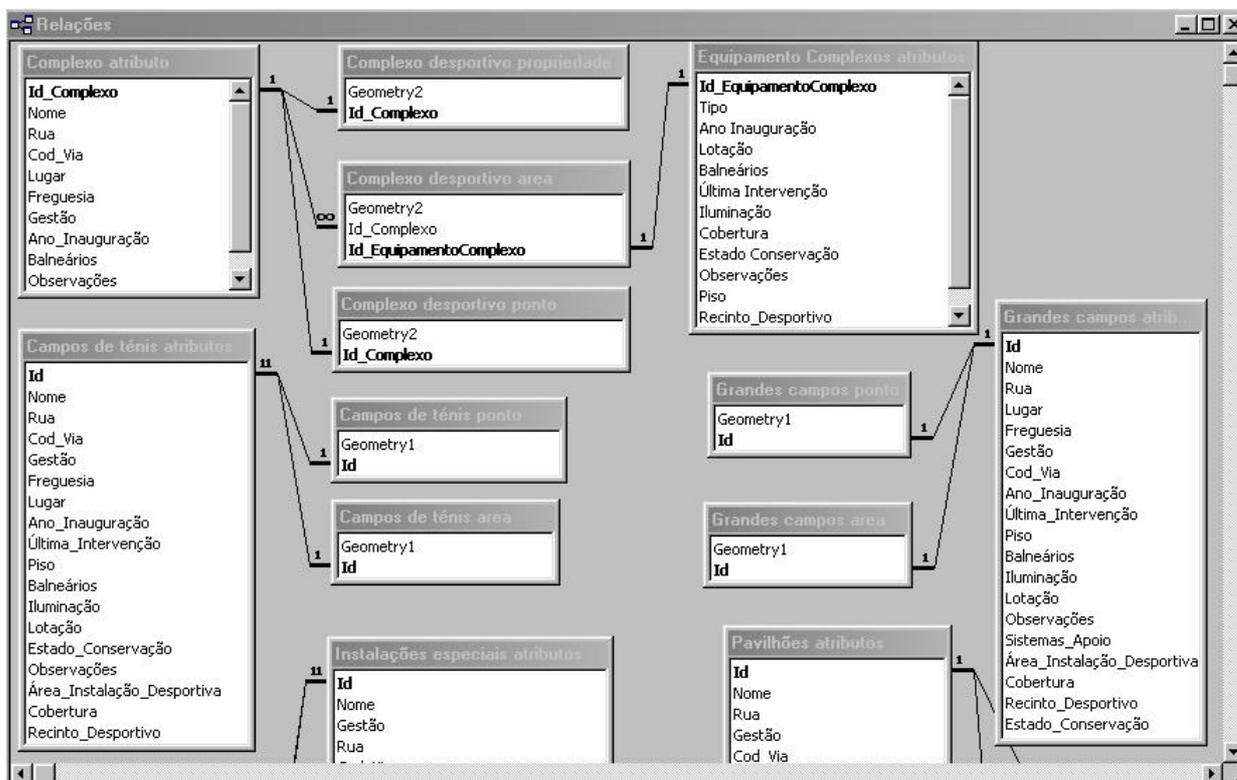


Figura A4.3 – Relações do modelo de dados do Equipamento desportivo.

Actividades económicas

A implementação dos dados relativos às Actividades económicas envolveu a construção de um conjunto de oito tabelas, apresentadas no quadro A4.3: Identificação, Características, Classificação, Actividades económicas, Sistema de tratamento de resíduos sólidos, Sistema de tratamento de efluentes, Matérias primas utilizadas e Produtos fabricados. A recolha da informação foi efectuada por uma equipa de campo constituída por funcionários da CMMG.

A tabela Actividades económicas contém a localização geográfica de todas as actividades económicas identificadas pela CMMG. Na figura A4.4 apresentam-se as relações do modelo de dados das Actividade económicas. A figura A4.5 exemplifica uma área da imagem onde foram identificadas as várias actividades económicas.

Quadro A4.3 – Categorias, Tabelas geográficas , Geometria e Tabelas alfanuméricas das Actividades económicas.

Categorias	Tabelas geográficas (Features)	Geometria	Tabelas alfanuméricas
Actividades económicas	Actividades económicas	Área	Identificação empresas
			Características empresas
			Tratamento efluentes
			Tratamento resíduos sólidos
			Matérias primas utilizadas
			Produtos fabricados

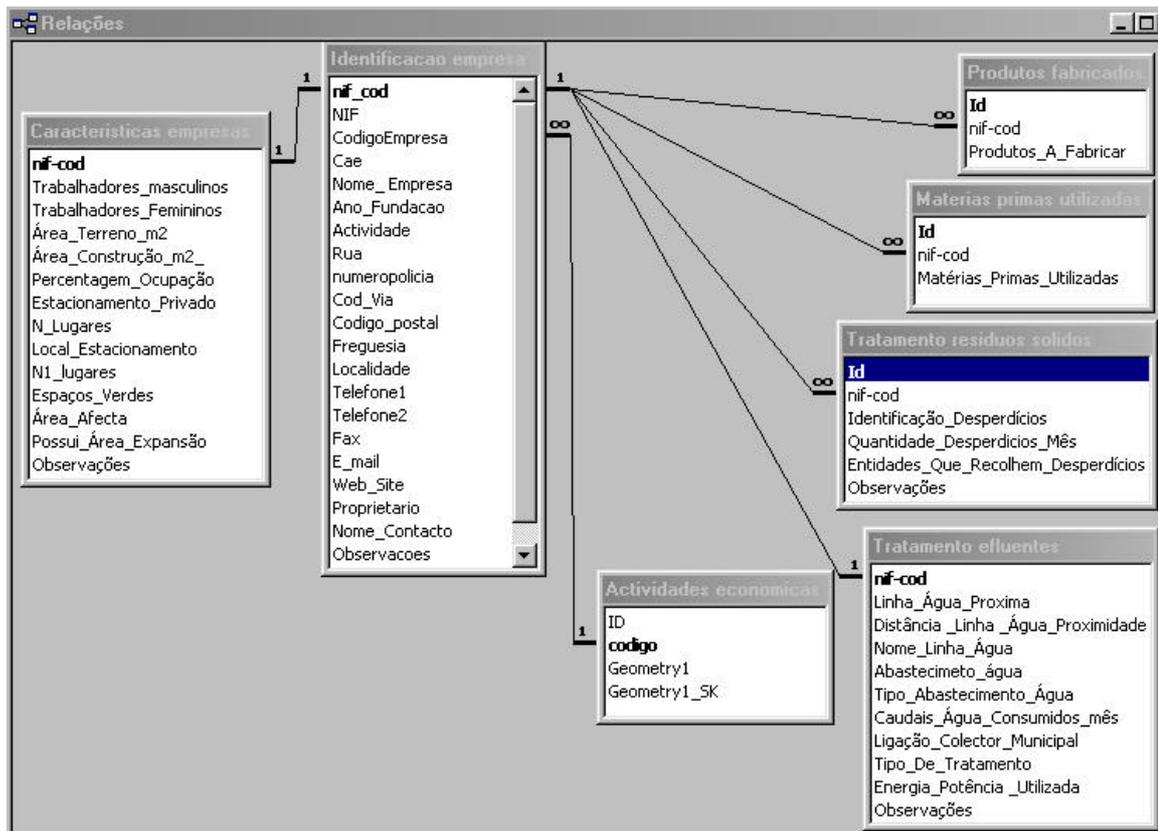


Figura A4.4 – Relações do modelo de dados das Actividades económicas.



Figura A4.5 – Resultado de uma consulta simples às actividades económicas sobreposta à imagem IKONOS (RGB 321). A azul estão representadas as actividades ligadas à fabricação de produtos; a vermelho o comércio e a amarelo os serviços.

Rede viária

A referência da rede viária efectuada está intimamente associada à dos topónimos de ruas, praças, largos, avenidas, etc.. No trabalho realizado procedeu-se à digitalização dos eixos de via e da rede viária pelas bermas do arruamento. Posteriormente, foi efectuada a ligação com a tabela contendo a informação da toponímia, para possibilitar a visualização conjunta desta informação.

A base de dados é constituída por 3 tabelas: Eixo de vias, Vias polígono e Topónimos conforme apresentado no quadro A4.4. Na figura A4.6 são apresentadas as relações do modelo de dados da rede viária. A figura A4.7 exemplifica uma área da imagem com a rede viária identificada.

Quadro A4.4 – Categorias, Tabelas geográficas, Geometria e Tabelas alfanuméricas da Rede viária.

Categorias	Tabelas geográficas (Features)	Geometria	Tabelas alfanuméricas
Rede viária	Eixo de Vias	Linha	Toponímia
	Vias Poligono	Área	

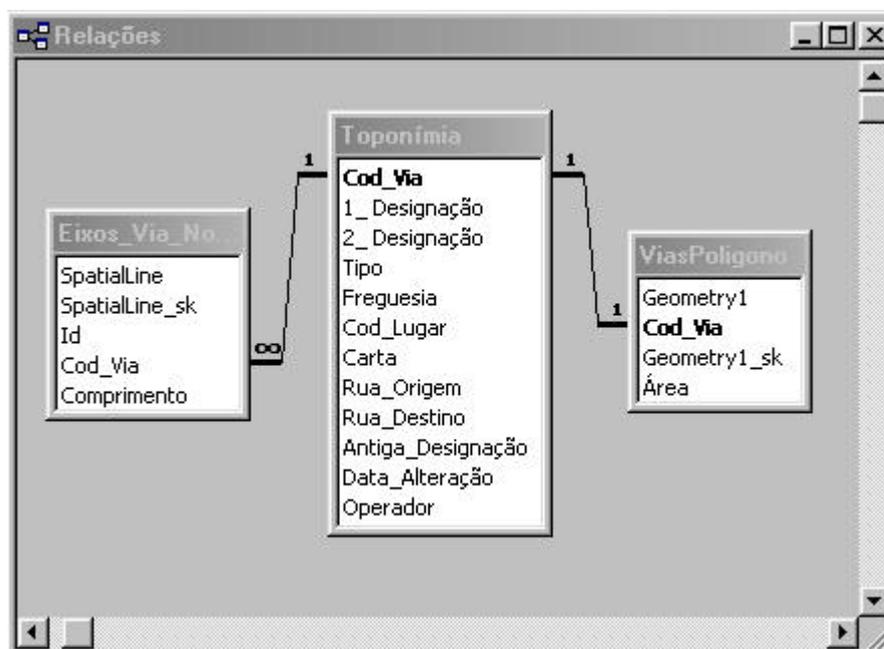


Figura A4.6 – Relações do modelo de dados da Rede viária.

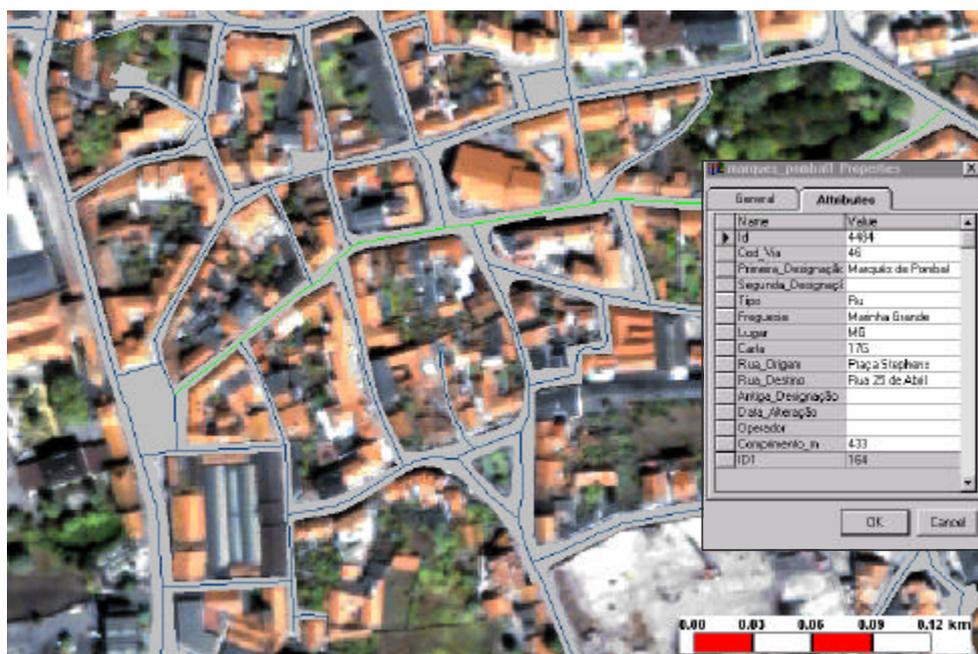


Figura A4.7 – Extracto da área de estudo com a rede viária existente sobreposta à imagem IKONOS (RGB 321). Os atributos são relativos ao eixo de via seleccionado (cor verde).

Serviços de utilidade pública e administração local, património e etar

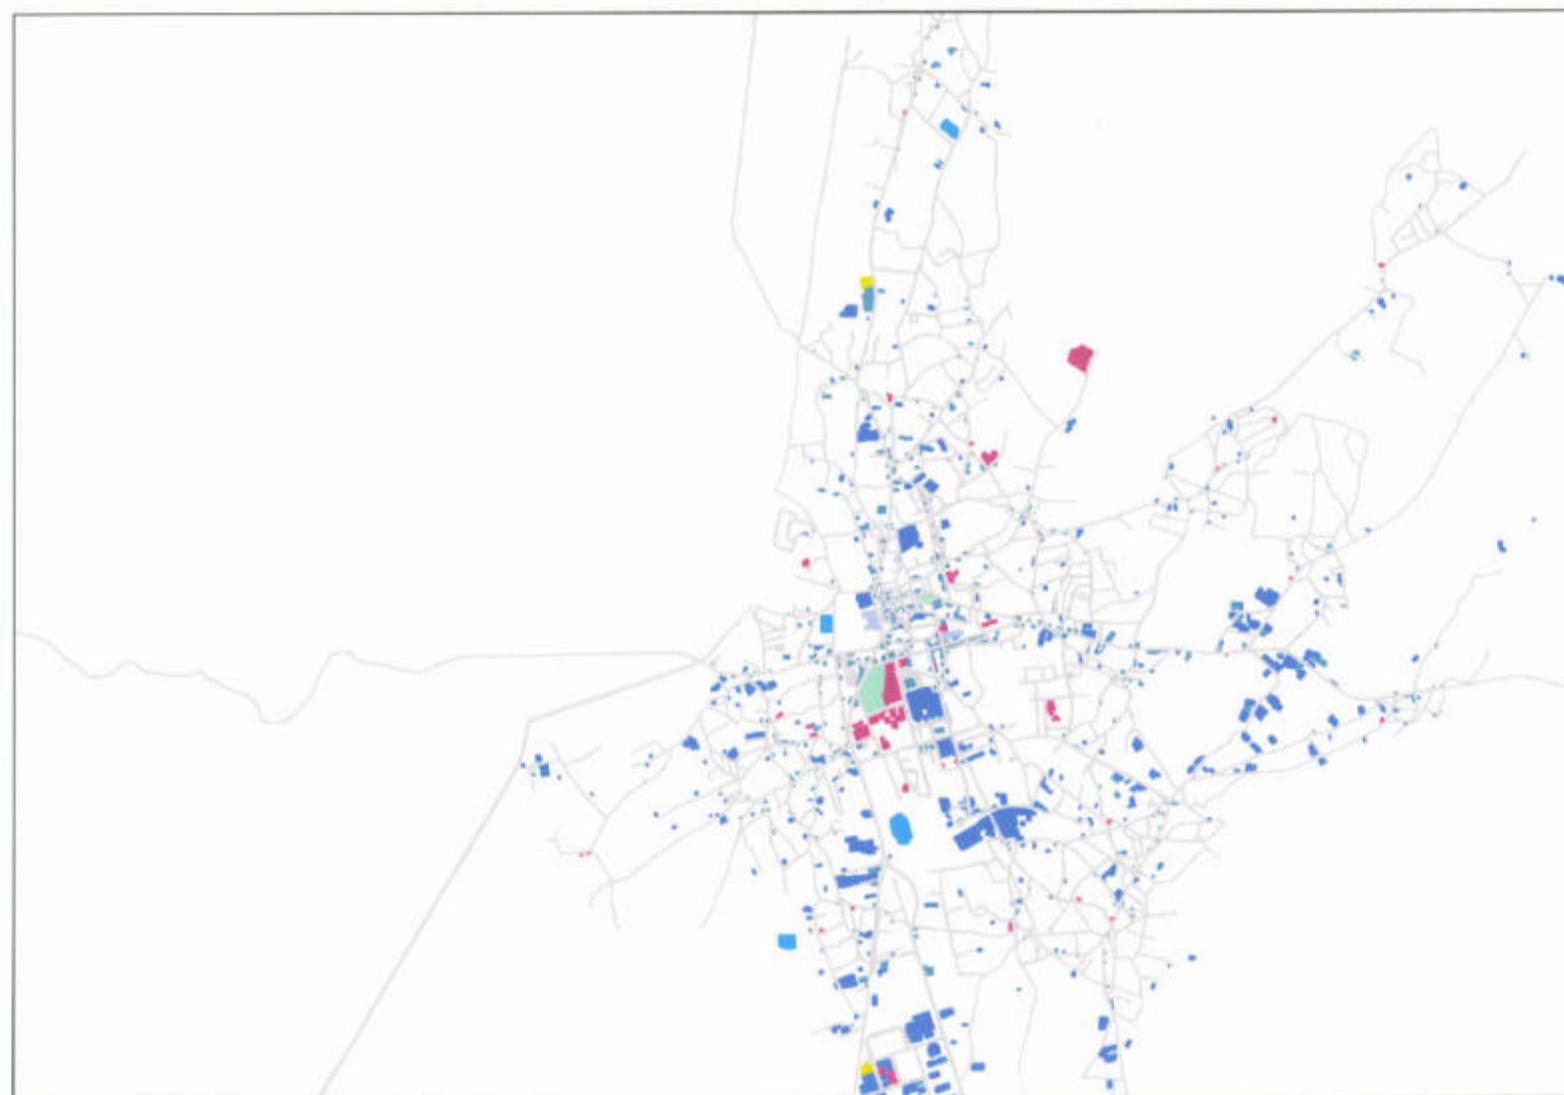
A informação relativamente aos Serviços de utilidade pública e administração local foi estruturada em 4 tabelas geográficas: Administração local, Serviços públicos, Segurança pública, Serviços de saúde pública. A informação relativa a Zonas históricas e espaços culturais foi estruturada em duas tabelas geográficas: Património e Cultura, conforme apresentado no quadro. Para estruturar a informação das Etar foi criada apenas uma tabela geográfica.

Quadro A4.5 – Categorias, Tabelas geográficas e Geometria do Património, Serviços de utilidade pública e Administração local.

Categorias	Tabelas Geográficas (Features)	Geometria
Serviços públicos e de administração local	Administração local	Área
	Serviços públicos	
	Serviços de saúde pública	
	Segurança pública	
Zonas históricas e espaços culturais	Património	Área
	Cultura	
Etar	Etar	Área

ANEXO 5 – Mapa dos dados auxiliares

Dados Auxiliares Utilizados no Concelho da Marinha Grande



- 112 - Serviços Utilidade Pública e Administração Local
- 1211 - Zonas Industriais
- 1212 - Zonas Comerciais e Financeiras
- 1221 - Rede Viária
- 134 - Etares
- 141 - Espaços Verdes Urbanos
- 142 - Áreas Desportivas
- 143 - Zonas Históricas e Espaços Culturais

Escala 1:50 000

Dados Auxiliares Utilizados no Concelho da Marinha Grande



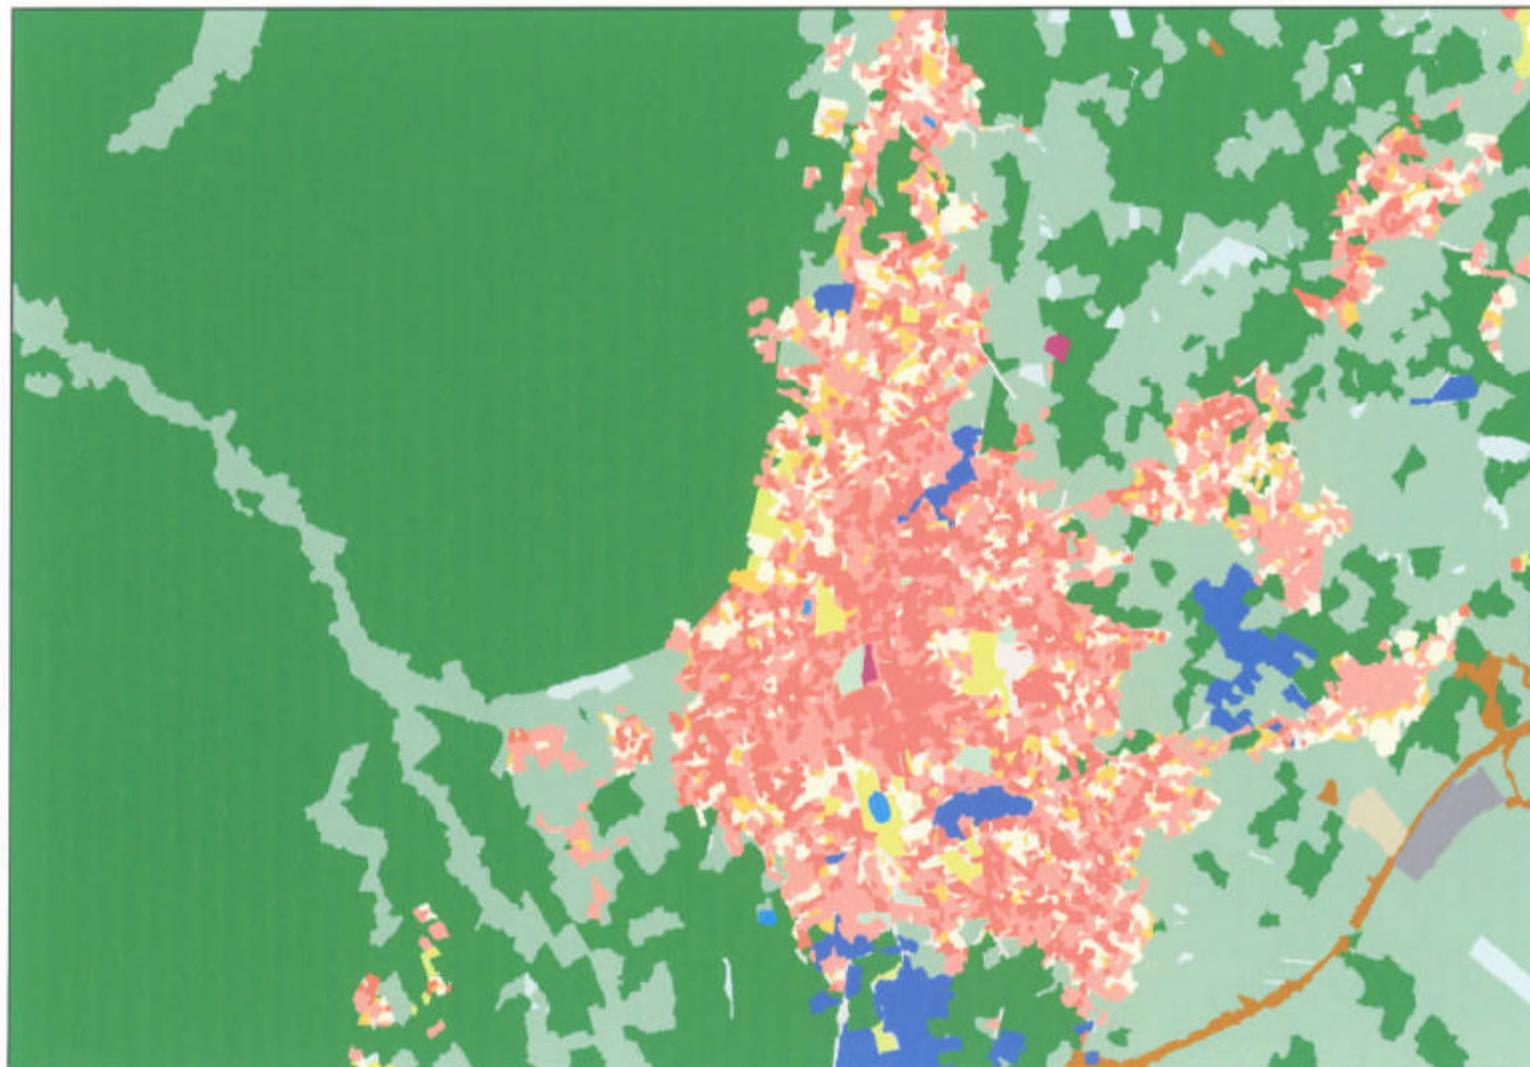
- 112 - Serviços Utilidade Pública e Administração Local
- 1211 - Zonas Industriais
- 1212 - Zonas Comerciais e Financeiras
- 1221 - Rede Viária
- 134 - Ectares
- 141 - Espaços Verdes Urbanos
- 142 - Áreas Desportivas
- 143 - Zonas Históricas e Espaços Culturais

Escala 1:10 000

ANEXO 6 – Mapa de ocupação do solo de 2000

Mapa de Ocupação do Solo

Área de Estudo no Concelho da Marinha Grande

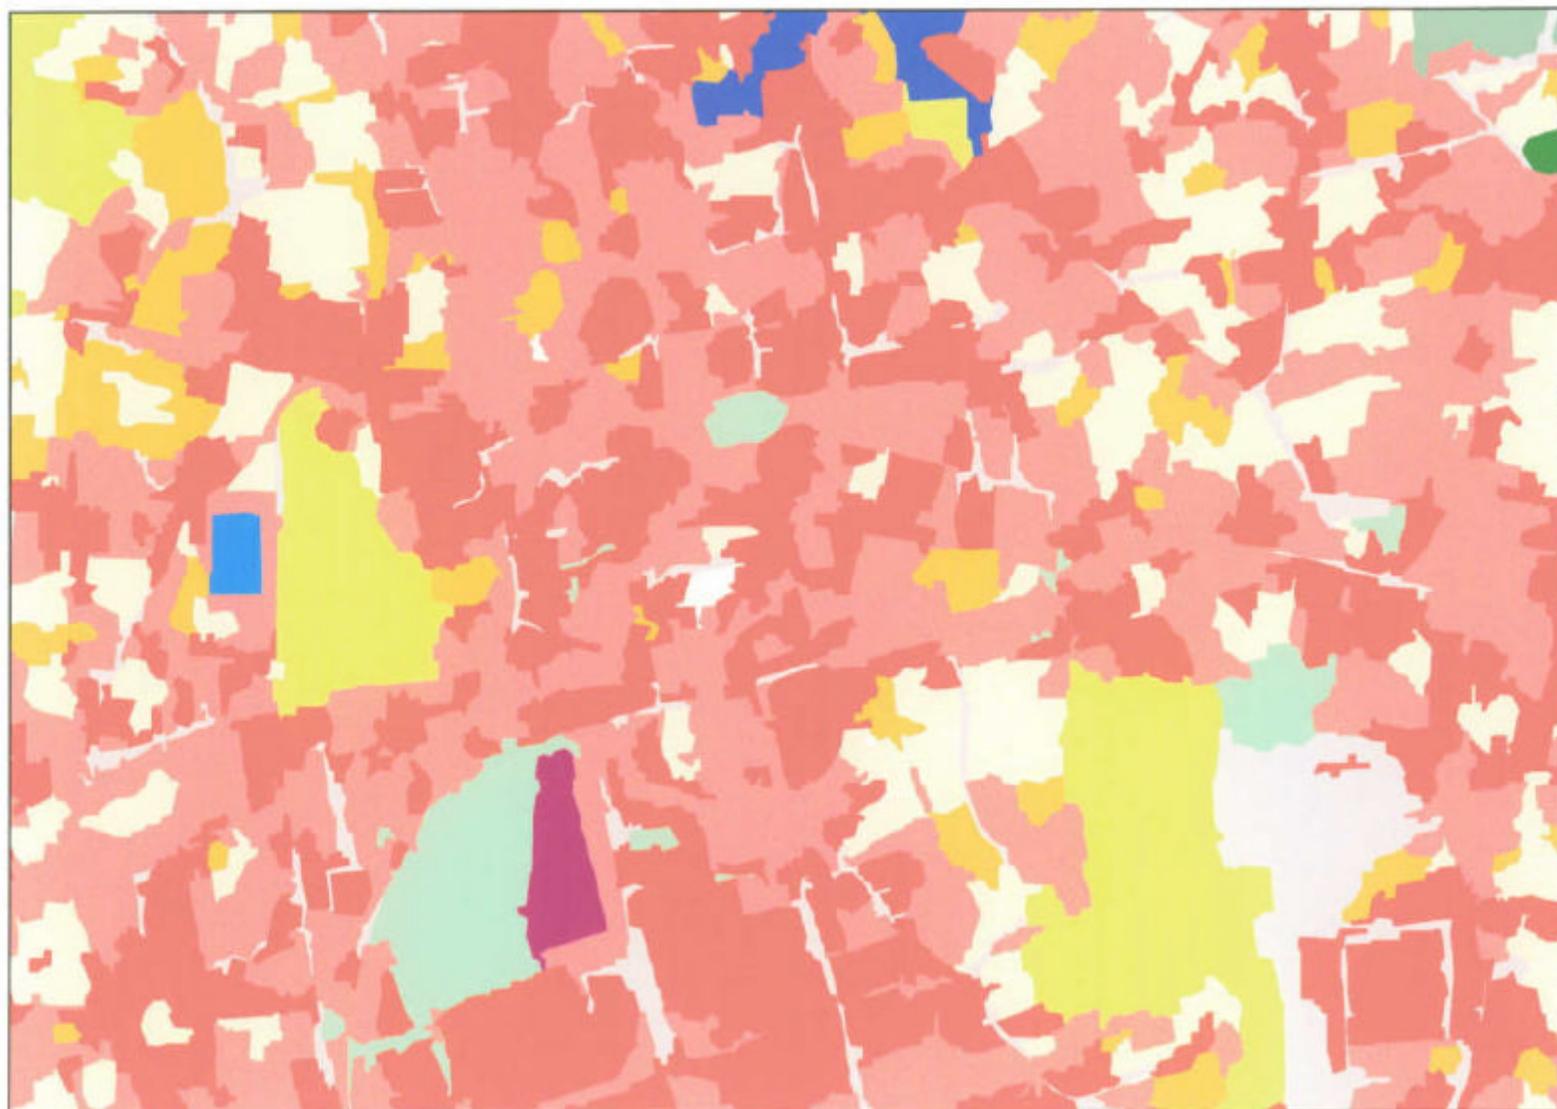


- 1111 - Áreas Residenciais Contínuas
- 1112 - Áreas Residenciais Descontínuas
- 112 - Serviços Utilidade Pública e Administração Local
- 1211 - Zonas Industriais
- 1221 - Rede Viária
- 131 - Salbreira
- 132 - Zonas de Lixeira
- 133 - Estaleiros
- 141 - Espaços Verdes Urbanos e de Recreio
- 142 - Áreas Desportivas
- 21 - Áreas Agrícolas com Culturas Anuais
- 24 - Áreas Agrícolas Heterogêneas
- 31 - Folhosas
- 32 - Resinosas
- 41 - Zonas com Vegetação Arbustiva e Herbácea
- 43 - Áreas Corte Floresta

Escala 1:50 000

Mapa de Ocupação do Solo

Área de Estudo no Concelho da Marinha Grande



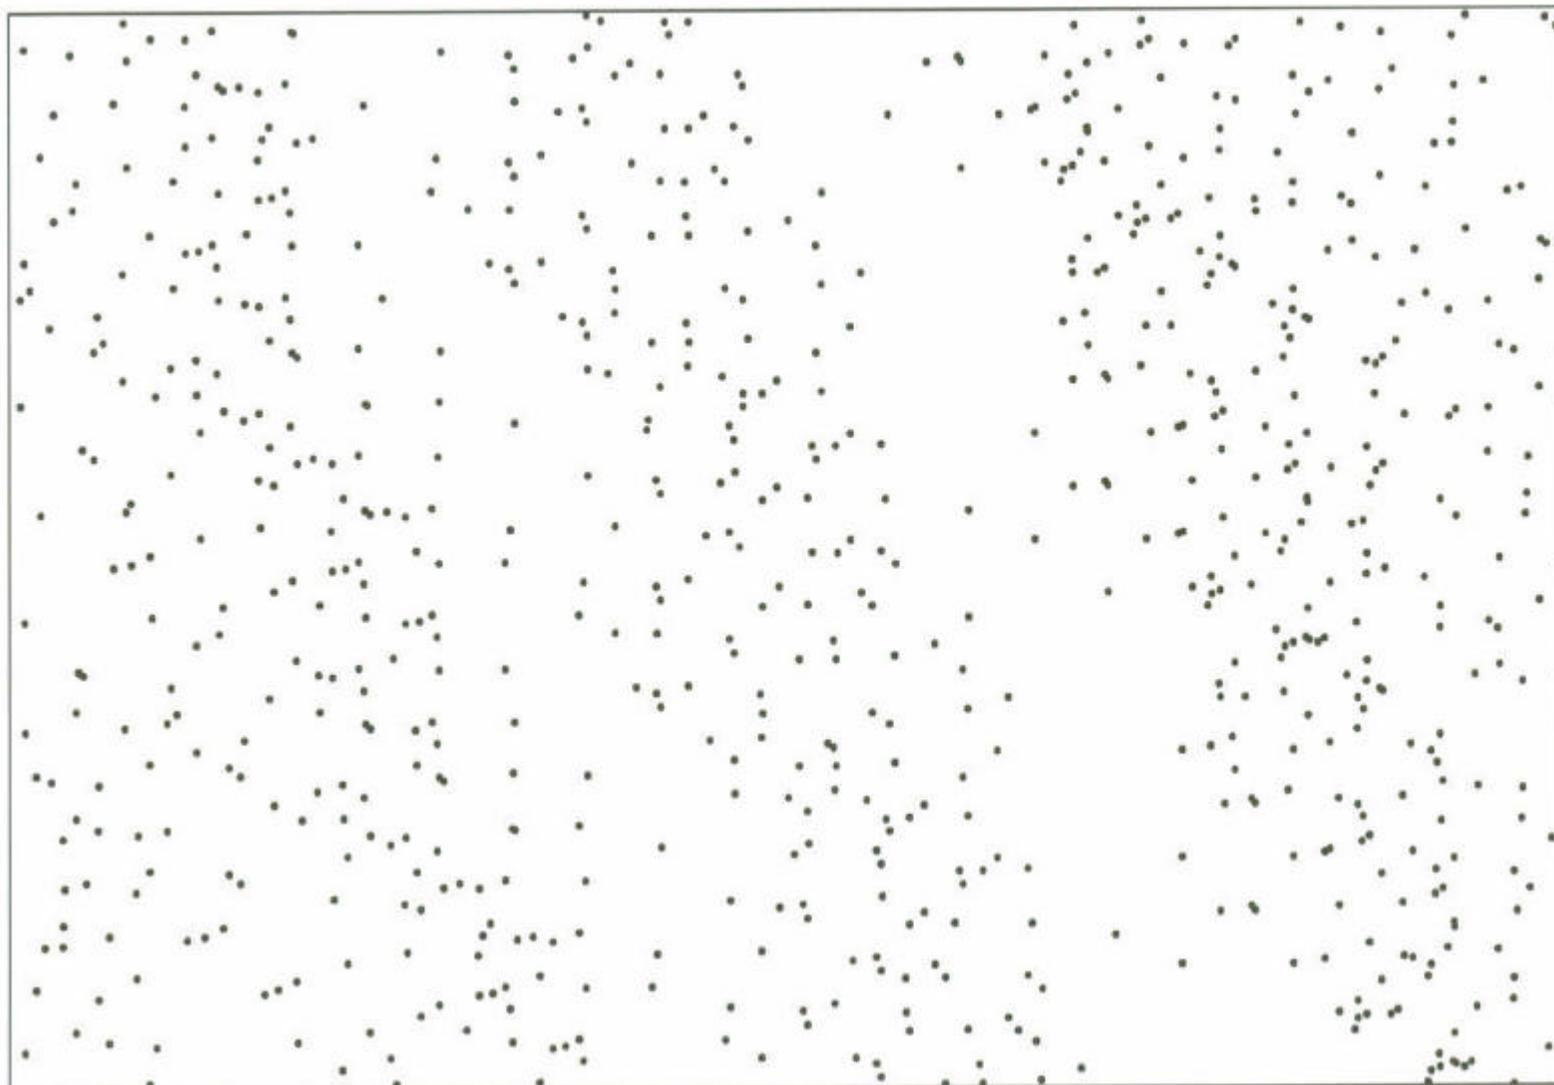
- 1111 - Áreas Residenciais Contínuas
- 1112 - Áreas Residenciais Descontínuas
- 112 - Serviços Utilidade Pública e Administração Local
- 1211 - Zonas Industriais
- 1221 - Rede Viária
- 131 - Saibreira
- 132 - Zonas de Lixeira
- 133 - Estaleiros
- 141 - Espaços Verdes Urbanos e de Recreio
- 142 - Áreas Desportivas
- 21 - Áreas Agrícolas com Culturas Anuais
- 24 - Áreas Agrícolas Heterogêneas
- 31 - Folhosas
- 32 - Resinosas
- 41 - Zonas com Vegetação Arbustiva e Herbácea
- 43 - Áreas Corte Floresta

Escala 1:10 000

ANEXO 7 – Distribuição dos pontos utilizados na validação dos mapas de ocupação do solo

Avaliação do Mapa de Ocupação do Solo

Distribuição das Amostras Utilizadas



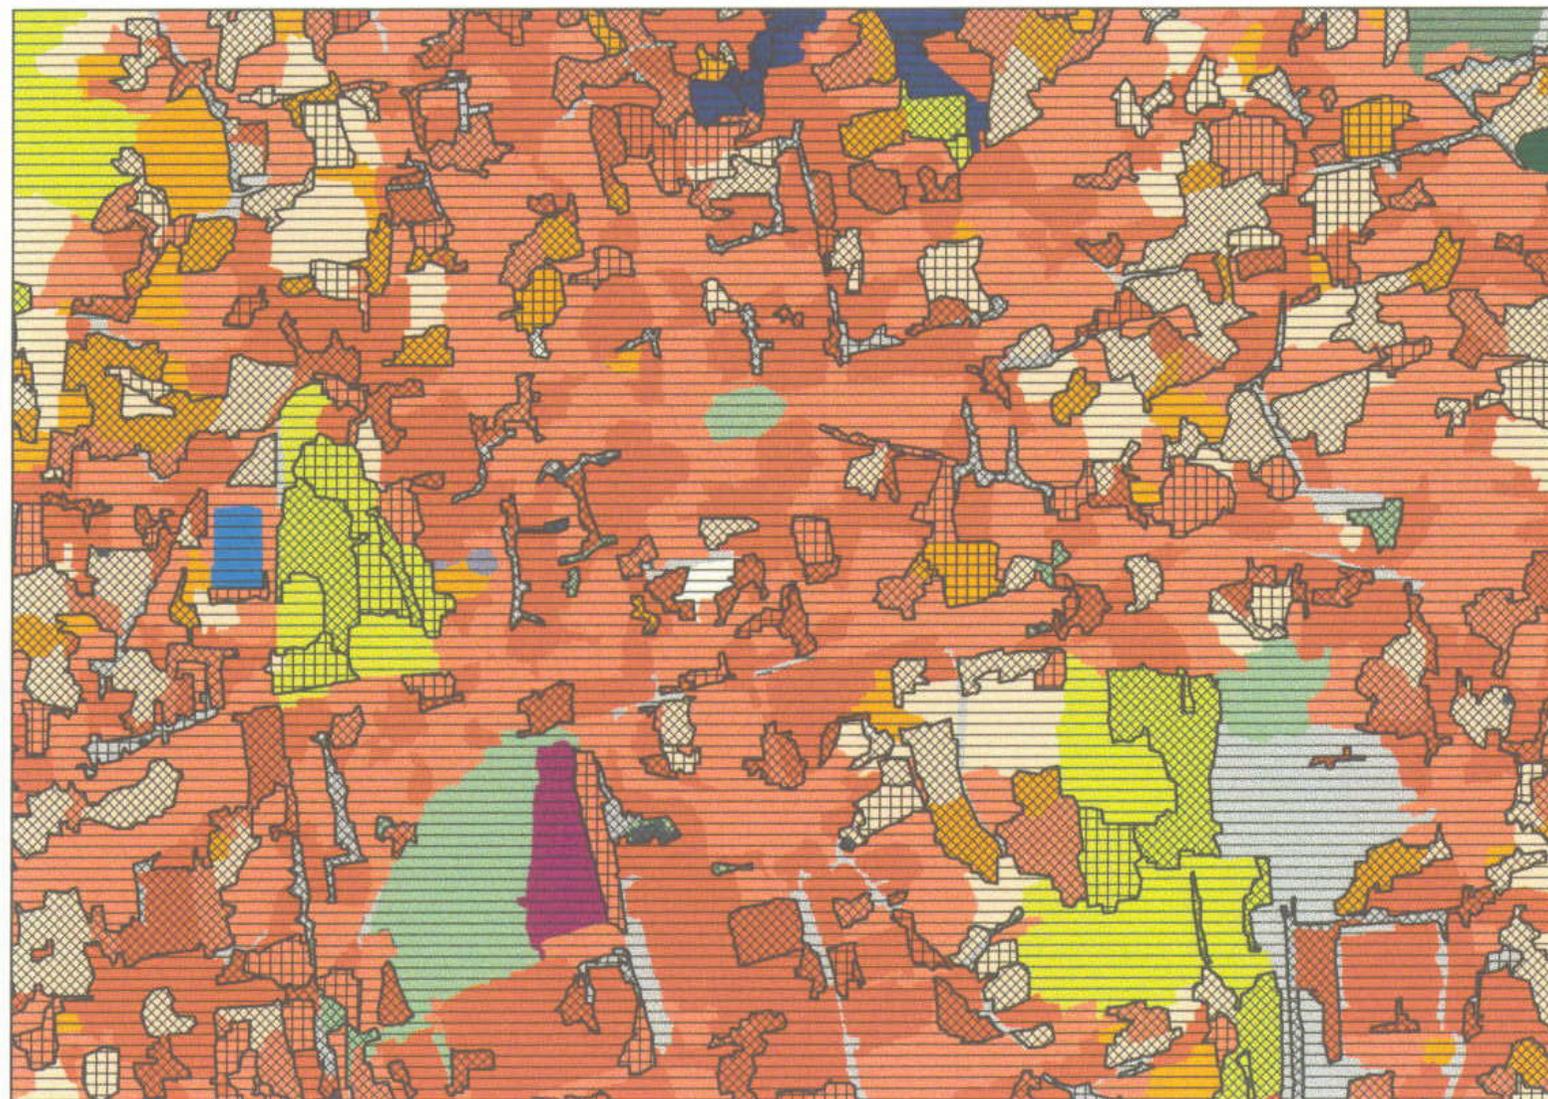
• Amostras

Escala 1:50 000

ANEXO 8 – Representação espacial da incerteza

Visualização da Incerteza Temática

Mapa de Ocupação do Solo -Área de Estudo no Concelho da Marinha Grande



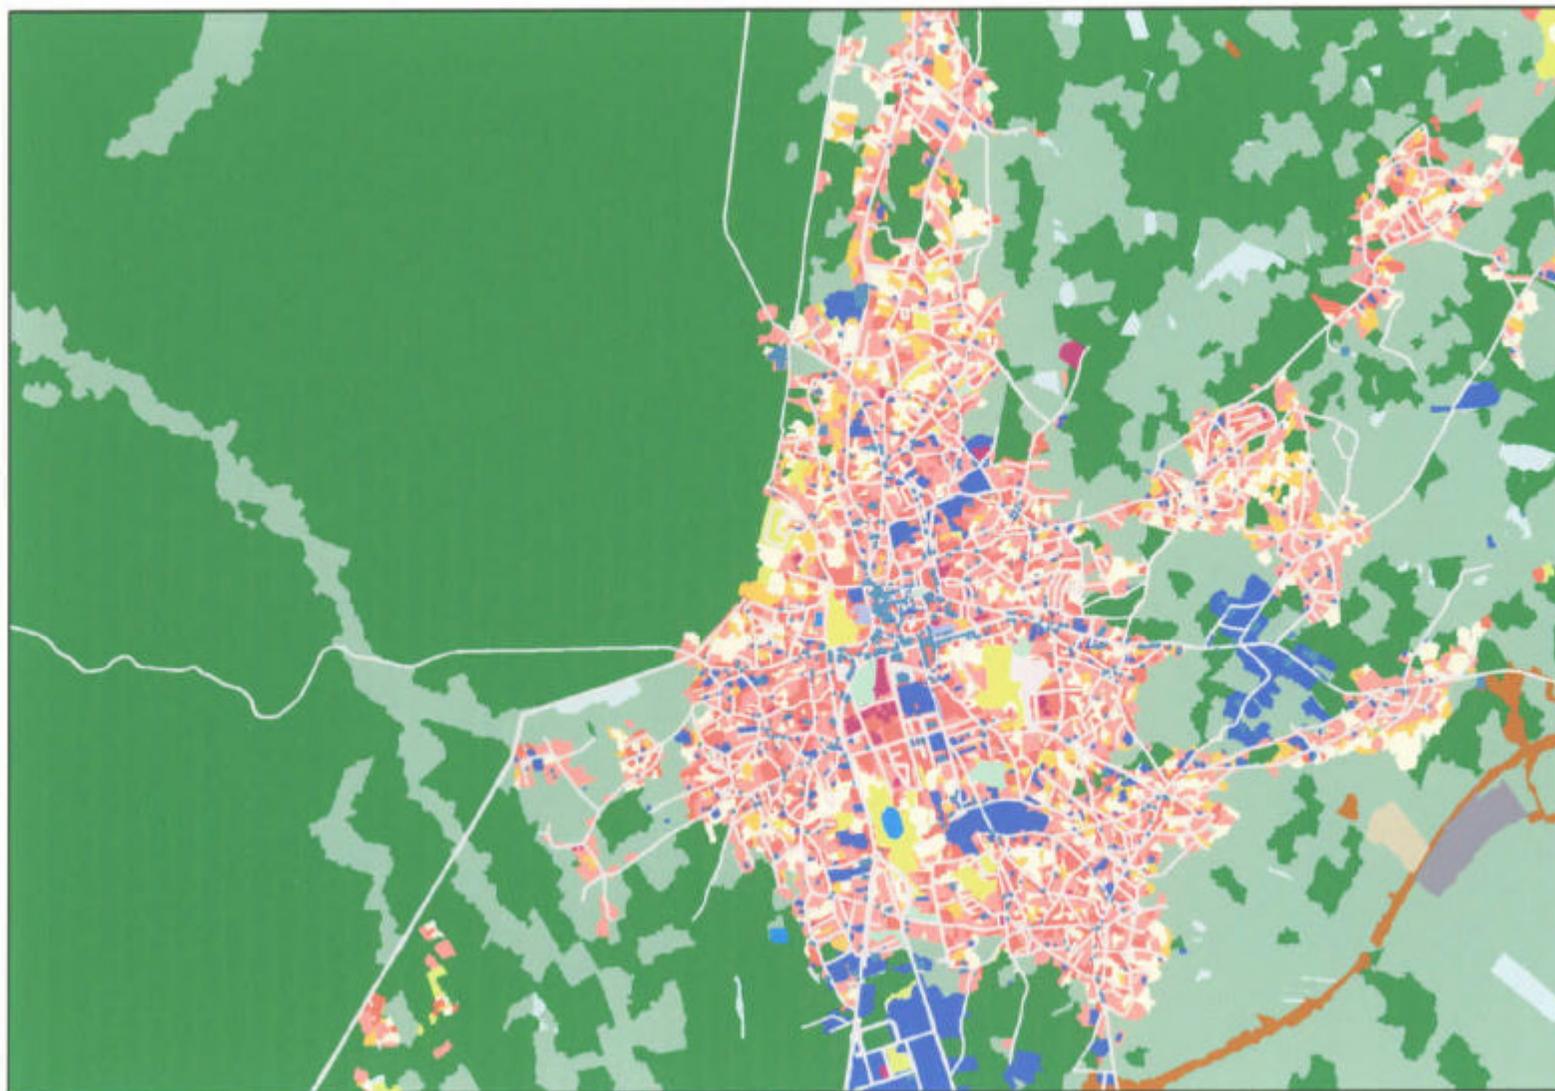
-  Grande Incerteza
-  Media Incerteza
-  Pouca Incerteza
-  1111 - Áreas Residenciais Contínuas
-  1112 - Áreas Residenciais Descontínuas
-  112 - Serviços Utilidade Pública e Administração Local
-  1211 - Zonas Industriais
-  1212 - Zonas Comerciais e Financeiras
-  1221 - Rede Viária
-  131 - Saibreira
-  132 - Zonas de Lixeira
-  133 - Estaleiros
-  134 - Etares
-  141 - Espaços Verdes Urbanos e de Recreio
-  142 - Áreas Desportivas
-  143 - Zonas Históricas e Espaços Culturais
-  21 Áreas Agrícolas com Culturas Anuais
-  24 - Áreas Agrícolas Heterogêneas
-  31 - Folhosas
-  32 - Resinosas
-  41 - Zonas com Vegetação Arbustiva e Herbácea
-  43 - Áreas Corte Floresta

Escala 1:10 000

ANEXO 9 – Mapa de ocupação do solo de 2000 com
integração de dados auxiliares

Mapa de Ocupação do Solo com Integração dos Dados Auxiliares

Área de Estudo no Concelho da Marinha Grande

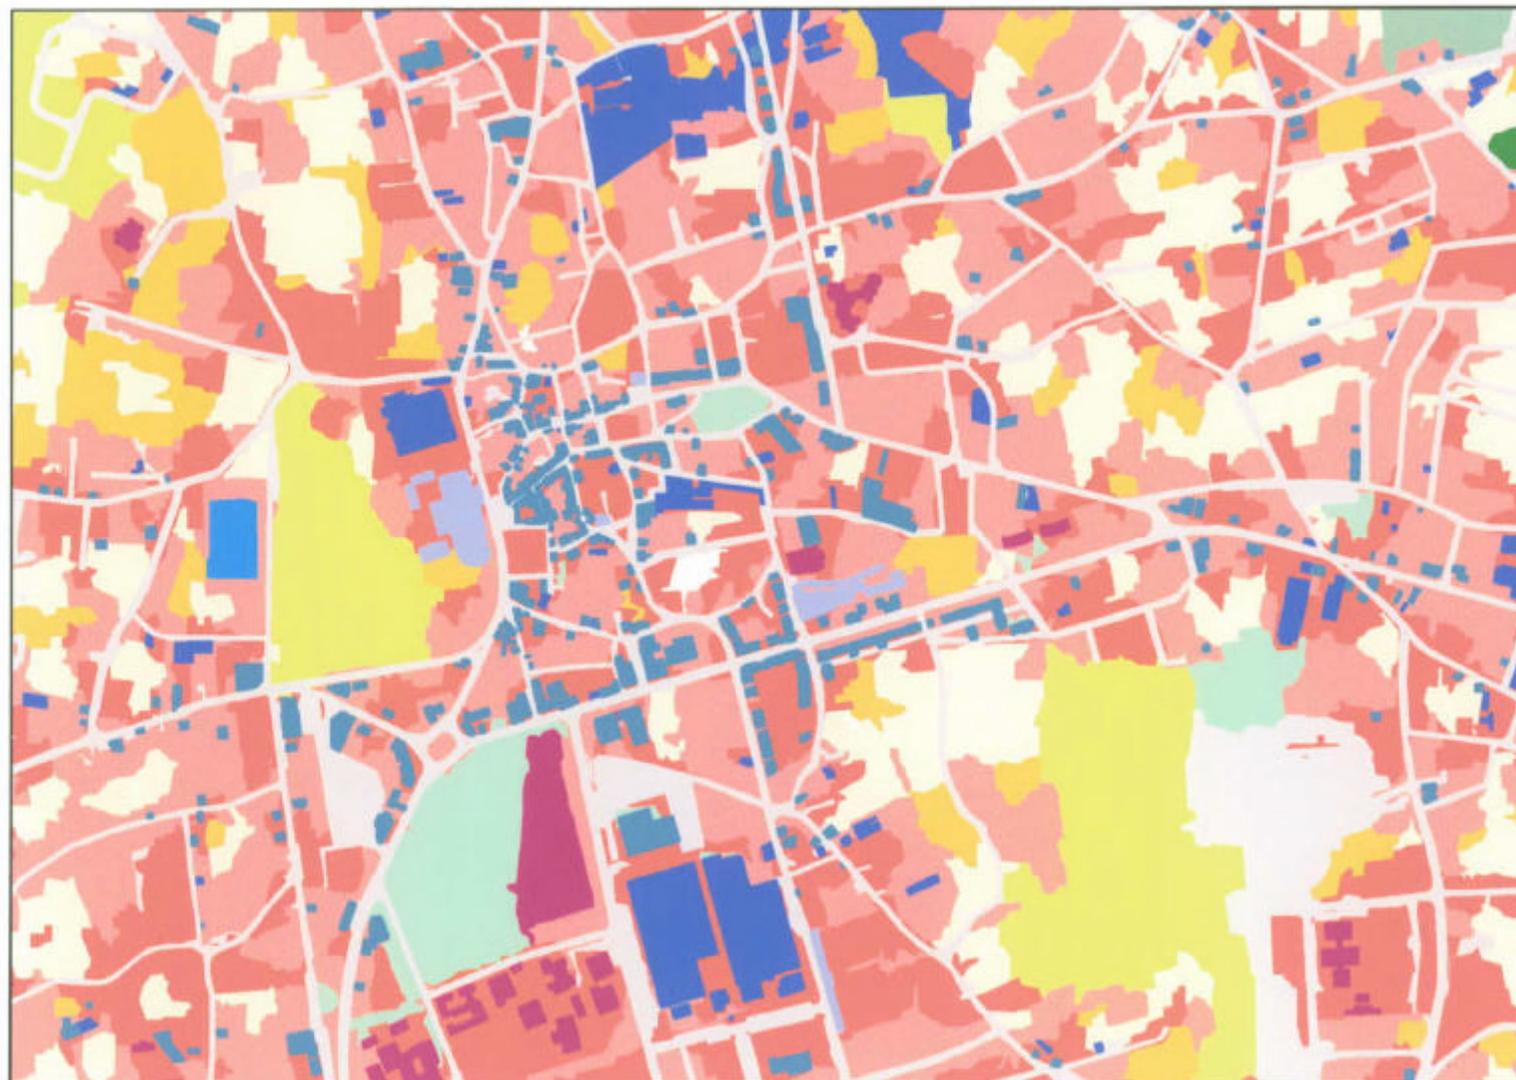


- 1111 - Áreas Residenciais Contínuas
- 1112 - Áreas Residenciais Descontínuas
- 112 - Serviços Utilidade Pública e Administração Local
- 1211 - Zonas Industriais
- 1212 - Zonas Comerciais e Financeiras
- 1221 - Rede Viária
- 131 - Saibreira
- 132 - Zonas de Lixeira
- 133 - Estaleiros
- 134 - Estares
- 141 - Espaços Verdes Urbanos e de Recreio
- 142 - Áreas Desportivas
- 143 - Zonas Históricas e Espaços Culturais
- 21 - Áreas Agrícolas com Culturas Anuais
- 24 - Áreas Agrícolas Heterogêneas
- 31 - Folhosas
- 32 - Resinosas
- 41 - Zonas com Vegetação Arbustiva e Herbáceas
- 43 - Áreas Corte Floresta

Escala 1:50 000

Mapa de Ocupação do Solo com Integração dos Dados Auxiliares

Área de Estudo no Concelho da Marinha Grande



- 1111 - Áreas Residenciais Contínuas
- 1112 - Áreas Residenciais Descontínuas
- 112 - Serviços Utilidade Pública e Administração Local
- 1211 - Zonas Industriais
- 1212 - Zonas Comerciais e Financeiras
- 1221 - Rede Viária
- 131 - Seibreira
- 132 - Zonas de Lixeira
- 133 - Estaleiros
- 134 - Etares
- 141 - Espaços Verdes Urbanos e de Recreio
- 142 - Áreas Desportivas
- 143 - Zonas Históricas e Espaços Culturais
- 21 - Áreas Agrícolas com Culturas Anuais
- 24 - Áreas Agrícolas Heterogêneas
- 31 - Folhosas
- 32 - Resinosas
- 41 - Zonas com Vegetação Arbustiva e Herbácea
- 43 - Áreas Corte Floresta

Escala 1:10 000