

UNIVERSIDADE DE LISBOA
INSTITUTO DE GEOGRAFIA E ORDENAMENTO DO TERRITÓRIO



**DETERMINAÇÃO SEMIAUTOMÁTICA DE LIMIARES
PARA CLASSIFICAÇÃO DE CONJUNTOS MULTITEMPORAIS
DE IMAGENS DE SATÉLITE**

Ângela Sofia Marques Barbosa

Dissertação

Mestrado em Sistemas de Informação Geográfica e
Modelação Territorial Aplicados ao Ordenamento

2016

UNIVERSIDADE DE LISBOA
INSTITUTO DE GEOGRAFIA E ORDENAMENTO DO TERRITÓRIO



**DETERMINAÇÃO SEMIAUTOMÁTICA DE LIMIARES
PARA CLASSIFICAÇÃO DE CONJUNTOS MULTITEMPORAIS
DE IMAGENS DE SATÉLITE**

Ângela Sofia Marques Barbosa

Dissertação orientada pelo Professor Doutor Jorge Rocha e
coorientada pela Professora Engenheira Ana Maria Fonseca

Mestrado em Sistemas de Informação Geográfica e
Modelação Territorial Aplicados ao Ordenamento

2016

Resumo

O desenvolvimento de métodos de classificação aplicados a imagens de satélite tem apresentado resultados bastante satisfatórios, nomeadamente a classificação baseada em objeto (OBIA – *Object Based Image Analysis*). Porém, os algoritmos construídos para a classificação de uma dada área de estudo, apresentam um desempenho inferior quando aplicados a uma imagem da mesma área, adquirida noutra época.

Assim, a presente dissertação de mestrado tem como principal objetivo desenvolver uma metodologia de classificação multitemporal de imagens de média resolução, semiautomática e replicável. Esta terá a capacidade de identificar os principais padrões de ocupação do solo de qualquer imagem na mesma área de estudo, sendo aplicada em diversos contextos temporais, permitindo a redução da subjetividade na classificação e uma rápida e constante atualização da informação, através da repetibilidade do algoritmo construído.

Foram recolhidas imagens do satélite *Land Remote Sensing Satellite 8* (Landsat 8) sendo estas subdivididas num conjunto de imagens de treino e de teste. De seguida, é desenvolvido um algoritmo de classificação de imagens orientada em objetos, através das imagens de treino com o auxílio *do software eCognition®*. Nesta primeira fase são encontradas as variáveis e os respetivos limiares de corte das funções, das imagens utilizadas na construção do algoritmo de classificação.

Posteriormente, através do *software Matrix Laboratory* (Matlab®) procedeu-se à aplicação de um algoritmo baseado na Análise por Componentes Principais (ACP) para determinar automaticamente os limiares de corte das funções para a classificação das imagens de teste. Este método multivariado permite numa primeira instância analisar a correlação entre parâmetros caracterizadores das imagens e os limiares das imagens de treino. Através de uma segunda ACP, as imagens de treino e de teste foram ordenadas e foi efetuada a interpolação dos limiares de corte das funções para as imagens a classificar. Foram produzidos mapas de ocupação de solo para 8 imagens, com uma exatidão global superior a 94% e um coeficiente de concordância *Kappa* acima de 0,94.

PALAVRAS-CHAVE: Detecção Remota, Classificação Semiautomática Orientada em Objetos, Ocupação do Solo, Análise por Componentes Principais.

Abstract

The analysis and classification of land cover images show a clear dependence on the user not only to identify the classes of a given area, but also at their extraction through a classification methodology.

However, the constant change in land cover over time also contributes to a delay in updating the information and subjectivity in the image classification. Thus, this master thesis aims to develop a methodology of medium resolution images classification, semiautomatic and replicable.

The algorithm developed has the ability to identify key land cover patterns of any image, to be applied in different temporal, allowing the reduction of subjectivity in the classification and rapid and constant updating of information.

In order to achieve the presented purpose, was developed a methodology based on oriented image classification on objects (OBIA - Object Based Image Analysis), with the help of software eCognition®, to apply the images collected from the Landsat 8 (Land Remote Sensing Satellite) satellite sensor. In this first phase was classified a set of training images with visual selection of cutoff thresholds for variables used to build the classification algorithm.

Later, through the Matlab® software (Matrix Laboratory) it proceeded to the application of an algorithm, based on Principal Component Analysis (PCA) to automatically determine the cutoff thresholds for classification of a new set of images (test image). The multivariate method allows to analyze in a first instance, the correlation between the parameters characterizing images and the reference images thresholds. Through a second PCA the reference and test images, were ordered and carried out the interpolation of cutting thresholds for the images to classify. Land cover maps were produced for 8 images, with a global accuracy greater than 94% and a Kappa coefficient of agreement above 0.94.

KEYWORDS: Remote Sensing, Object Oriented Semiautomatic Classification, Land Cover, Principal Component Analysis.

Índice Geral

CAPÍTULO 1 - INTRODUÇÃO	1
1.1. OBJETIVOS	7
1.2. ORGANIZAÇÃO DA DISSERTAÇÃO	7
CAPÍTULO 2 - USO E OCUPAÇÃO DO SOLO	9
2.1. SISTEMAS DE CLASSIFICAÇÃO	13
2.2. MÉTODOS DE CLASSIFICAÇÃO	14
2.3. SISTEMAS HIERÁRQUICOS E NÃO-HIERÁRQUICOS	16
CAPÍTULO 3 - NOMENCLATURAS DE USO E OCUPAÇÃO DO SOLO	19
3.1. GLOBAL LAND COVER	19
3.2. INVENTÁRIO CORINE LAND COVER	21
3.3. INVENTÁRIO FLORESTAL NACIONAL	24
3.4. CARTA DE OCUPAÇÃO DO SOLO DE PORTUGAL	26
3.5. COMPARAÇÃO DAS NOMENCLATURAS	30
CAPÍTULO 4 - DETEÇÃO REMOTA	33
4.1. FORMAÇÃO DA IMAGEM	33
4.1. RESOLUÇÃO RADIOMÉTRICA, ESPECTRAL E ESPACIAL	34
4.2. ASSINATURAS ESPECTRAIS	35
4.3. PROCESSAMENTO DE IMAGEM PÍXEL-A-PÍXEL	37
4.4. PROCESSAMENTO DE IMAGEM BASEADA EM OBJETO	38
4.4.1. <i>Segmentação – Requisitos, desempenho e reprodutibilidade</i>	40
4.4.2. <i>Requisitos para a segmentação</i>	42
4.4.3. <i>Desempenho do algoritmo</i>	43
4.4.4. <i>Reprodutibilidade dos resultados</i>	45
4.4.5. <i>Modelação semântica e classificação</i>	47
CAPÍTULO 5 - CLASSIFICAÇÃO (SEMI)AUTOMÁTICA BASEADA EM OBJETOS	49
5.1. CONTEXTUALIZAÇÃO METODOLÓGICA	50
5.2. O CONCEITO DE OBJETO	52
5.3. CLASSIFICAÇÃO DE IMAGEM BASEADA EM OBJETO (OBIA)	56
5.4. OBIA VERSUS GEOBIA	58
5.4.1. <i>Construção de Objetos</i>	59
5.4.2. <i>Parâmetros da segmentação</i>	61
5.4.3. <i>Classificação de imagens</i>	67

CAPÍTULO 6 - MATERIAL E MÉTODOS	71
6.1. ENQUADRAMENTO DA UNIDADE DE ANÁLISE	71
6.2. CARACTERIZAÇÃO DA OCUPAÇÃO DO SOLO	73
6.3. IMAGENS DE SATÉLITE LANDSAT	75
6.4. PROGRAMAS INFORMÁTICOS	83
6.5. METODOLOGIA DE ANÁLISE	85
6.6. DEFINIÇÃO DA NOMENCLATURA DE OCUPAÇÃO DO SOLO	87
CAPÍTULO 7 - APLICAÇÃO DO ALGORITMO DE CLASSIFICAÇÃO	91
7.1. ALGORITMO DE SEGMENTAÇÃO	91
7.2. VARIÁVEIS UTILIZADAS E IDENTIFICAÇÃO DE LIMIARES	93
7.2.1. <i>Transformação de bandas</i>	94
7.2.2. <i>Identificação de limiares</i>	99
7.3. ALGORITMO DE CLASSIFICAÇÃO	102
7.4. DETERMINAÇÃO SEMIAUTOMÁTICA DE LIMIARES	108
7.4.1. <i>Cálculo dos limiares</i>	110
7.4.2. <i>Teste de sensibilidade à metodologia de classificação multitemporal</i>	115
CAPÍTULO 8 - AVALIAÇÃO DE RESULTADOS	117
8.1. CARTOGRAFIA DE OCUPAÇÃO DO SOLO	117
8.2. AVALIAÇÃO DA EXATIDÃO TEMÁTICA	119
8.2.1. <i>Amostragem</i>	120
8.2.2. <i>Criação da amostra para a avaliação da exatidão</i>	124
8.2.3. <i>Recolha de dados para cada amostra</i>	125
8.2.4. <i>Análise dos resultados</i>	126
8.3. AVALIAÇÃO DA EXATIDÃO TEMÁTICA POR IMAGEM	129
8.4. AVALIAÇÃO DA EXATIDÃO TEMÁTICA POR CLASSE	131
8.5. AVALIAÇÃO DA EXATIDÃO TEMÁTICA DO TESTE DE SENSIBILIDADE À METODOLOGIA DE CLASSIFICAÇÃO MULTITEMPORAL	134
CAPÍTULO 9 - CONSIDERAÇÕES FINAIS	139
REFERÊNCIAS BIBLIOGRÁFICAS	143
ANEXO	161

Índice de Figuras

CAPÍTULO 2 - USO E OCUPAÇÃO DO SOLO

FIGURA 2.1 - EXEMPLO DE UM SISTEMA DE CLASSIFICAÇÃO <i>A PRIORI</i> RELATIVAMENTE A UMA SITUAÇÃO CONCRETA NO TERRENO (ADAPTADO DE KUECHLER E ZONNEVELD, 1988)	15
FIGURA 2.2 - PROBLEMAS DAS CLASSIFICAÇÕES <i>A PRIORI</i> RELATIVAMENTE À SUA FLEXIBILIDADE	16
FIGURA 2.3 - EXEMPLO DE UM SISTEMA DE CLASSIFICAÇÃO <i>A POSTERIORI</i> RELATIVAMENTE A UMA SITUAÇÃO CONCRETA NO TERRENO (ADAPTADO DE KUECHLER E ZONNEVELD, 1988)	16
FIGURA 2.4 - RELAÇÕES HIERÁRQUICAS	17
FIGURA 2.5 - RELAÇÕES NÃO-HIERÁRQUICAS	18

CAPÍTULO 3 - NOMENCLATURAS DE USO E OCUPAÇÃO DO SOLO

FIGURA 3.1 - ESCALAS ESPACIAIS HIERÁRQUICAS	31
FIGURA 3.2 - SISTEMAS DE CLASSIFICAÇÃO DE ACORDO COM AS SUAS CARACTERÍSTICAS	32

CAPÍTULO 4 - DETEÇÃO REMOTA

FIGURA 4.1 - DIFERENTES RESOLUÇÕES ESPACIAIS	35
FIGURA 4.2 - ASSINATURAS ESPECTRAIS DE DIFERENTES SUPERFÍCIES (ADAPTADO DE RICHARDS E JIA, 1999)	36

CAPÍTULO 5 - CLASSIFICAÇÃO (SEMI)AUTOMÁTICA BASEADA EM OBJETOS

FIGURA 5.1 - TAXONOMIA DE ENTIDADES <i>BONA FIDE</i> E ENTIDADES <i>FIAT</i> (ADAPTADO DE SMITH, 2001)	53
FIGURA 5.2 - OBJETO COMPÓSITO	56
FIGURA 5.3 - PROCESSO DE SEGMENTAÇÃO DE IMAGENS POR CRESCIMENTO DE REGIÕES	60
FIGURA 5.4 - REDE HIERÁRQUICA DE OBJETOS (ADAPTADO DE BAATZ <i>ET AL.</i> , 2003)	64
FIGURA 5.5 - DIAGRAMA DE FLUXO DOS PARÂMETROS DE SEGMENTAÇÃO MULTIRESOLUÇÃO (TRIMBLE, 2012)	65
FIGURA 5.6 - EXTRAÇÃO DE OBJETOS EM DADOS DE IMAGEM ADQUIRIDA EM DOIS TEMPOS DIFERENTES	69

CAPÍTULO 6 - MATERIAL E MÉTODOS

FIGURA 6.1 - ENQUADRAMENTO DA IMAGEM LANDSAT 8 E RESPECTIVA ÁREA DE ESTUDO	72
FIGURA 6.2 - ENQUADRAMENTO GEOGRÁFICO DA ÁREA DE ESTUDO	73
FIGURA 6.3 - OCUPAÇÃO DO SOLO DA ÁREA DE ESTUDO NO NÍVEL 2 DO CLC DE 2006	74
FIGURA 6.4 - COMPARAÇÃO DO ESPECTRO ELETROMAGNÉTICO ENTRE O LANDSAT 1 E LANDSAT 8 (ADAPTADO DE USGS 2015)	80
FIGURA 6.5 - IMAGENS LANDSAT 8 SELECIONADAS	82
FIGURA 6.6 - FLUXOGRAMA GERAL DA METODOLOGIA	86
FIGURA 6.7 - EXEMPLOS DE CADA CLASSE DE OCUPAÇÃO DO SOLO PRESENTE NA ÁREA DE ESTUDO	89

CAPÍTULO 7 - APLICAÇÃO DO ALGORITMO DE CLASSIFICAÇÃO

FIGURA 7.1 - ESQUEMATIZAÇÃO DO ALGORITMO DE CLASSIFICAÇÃO	107
FIGURA 7.2 - ESQUEMA DA APLICAÇÃO DA ANÁLISE POR COMPONENTES PRINCIPAIS (VICINI, 2005)	109
FIGURA 7.3 - CÍRCULO DE CORRELAÇÃO	110
FIGURA 7.4 - ANÁLISE DA CORRELAÇÃO ENTRE AS VARIÁVEIS PARA O CONJUNTO DE IMAGENS DE TREINO (1ª ACP)	111

FIGURA 7.5 - PROJEÇÃO DAS IMAGENS DE TREINO E DE TESTE (2ª ACP)	113
CAPÍTULO 8 - AVALIAÇÃO DE RESULTADOS	
FIGURA 8.1 - CARTOGRAFIA DE OCUPAÇÃO DO SOLO DO CONJUNTO DE IMAGENS DE TREINO	118
FIGURA 8.2 - CARTOGRAFIA DE OCUPAÇÃO DO SOLO DO CONJUNTO DE IMAGENS DE TESTE	119
FIGURA 8.3 - TÉCNICAS DE RECOLHA DE AMOSTRAS: (A) PADRÃO REGULAR DE AMOSTRAS; (B) REDE REGULAR; (C) PROGRESSIVA; (D) SELETIVA; (E) COMPOSTA.	121
FIGURA 8.4 - MATRIZ DE CONFUSÃO COM Q CLASSES DE OCUPAÇÃO DO SOLO (ADAPTADO DE COSTA, 2008)	127
FIGURA 8.5 - COEFICIENTE DE CONCORDÂNCIA $KAPPA$ DE CADA IMAGEM CLASSIFICADA POR CLASSE DE OCUPAÇÃO DO SOLO	134

Índice de Tabelas

CAPÍTULO 5 - CLASSIFICAÇÃO (SEMI)AUTOMÁTICA BASEADA EM OBJETOS

TABELA 5.1 - DESENVOLVIMENTOS RECENTES NO ÂMBITO DA OBIA	51
--	----

CAPÍTULO 6 - MATERIAL E MÉTODOS

TABELA 6.1 - POSICIONAMENTO E SISTEMA DE COORDENADAS DAS IMAGENS LANDSAT8 RECOLHIDAS E DA ÁREA DE ESTUDO	72
TABELA 6.2 - ÁREA DE OCUPAÇÃO DO SOLO NA ÁREA DE ESTUDO NOS NÍVEIS 1 E 2 DA NOMENCLATURA DO CLC DE 2006	75
TABELA 6.3 - PRINCIPAIS CARACTERÍSTICAS DO PROGRAMA LANDSAT	78
TABELA 6.4 - PRINCIPAIS CARACTERÍSTICAS DOS SENSORES OLI E TIRS DO SATÉLITE LANDSAT 8	79
TABELA 6.5 - DATAÇÃO DAS IMAGENS LANDSAT 8 SELECIONADAS	81
TABELA 6.6 - SOFTWARE UTILIZADO NA EXECUÇÃO DO TRABALHO	85
TABELA 6.7 - DESIGNAÇÃO DAS CLASSES EM ESTUDO SEGUNDO A NOMENCLATURA CLC 2006	88

CAPÍTULO 7 - APLICAÇÃO DO ALGORITMO DE CLASSIFICAÇÃO

TABELA 7.1 - PARÂMETROS ADOTADOS NAS SEGMENTAÇÕES UTILIZADAS PARA A CLASSIFICAÇÃO DAS IMAGENS	92
TABELA 7.2 - DESCRIMINAÇÃO DA APLICAÇÃO DAS BANDAS LANDSAT 8	94
TABELA 7.3 - VARIÁVEIS E RESPECTIVOS LIMIARES PARA A CLASSIFICAÇÃO DAS 4 IMAGENS DE TREINO	101
TABELA 7.4 - DISCRICÃO DAS ALTERAÇÕES REALIZADAS AO LONGO DOS VÁRIOS ALGORITMOS DE CLASSIFICAÇÃO	102
TABELA 7.5 - DESCRIMINAÇÃO DAS VARIÁVEIS E PARÂMETROS A PRIORI PRESENTES EM CADA CLUSTER FORMADO ATRAVÉS DO CÍRCULO DE CORRELAÇÕES	112
TABELA 7.6 - VARIÁVEIS E RESPECTIVOS LIMIARES PARA A CLASSIFICAÇÃO DAS 4 IMAGENS DE TESTE	114

CAPÍTULO 8 - AVALIAÇÃO DE RESULTADOS

TABELA 8.1 - CODIFICAÇÃO DAS CLASSES DE OCUPAÇÃO DO SOLO	126
TABELA 8.2 - MEDIDAS GLOBAIS DE FIABILIDADE E RESPECTIVAS EQUAÇÕES	128
TABELA 8.3 - QUALIDADE DA CLASSIFICAÇÃO DOS VALORES DO COEFICIENTE DE CONCORDÂNCIA <i>KAPPA</i> (ADAPTADO DE MARTINS, 2012)	129
TABELA 8.4 - EXATIDÃO DO UTILIZADOR E PRODUTOR (%) E COEFICIENTE DE CONCORDÂNCIA <i>KAPPA</i> DAS IMAGENS DE TREINO E DE TESTE	130
TABELA 8.5 - ERROS DE COMISSÃO (%) DAS CLASSES DE OCUPAÇÃO DO SOLO NAS IMAGENS DE TREINO E DE TESTE	131
TABELA 8.6 - ERROS DE OMISSÃO (%) DAS CLASSES DE OCUPAÇÃO DO SOLO NAS IMAGENS DE TREINO E DE TESTE	132
TABELA 8.7 - CONTAGEM DO NÚMERO DE OBSERVAÇÕES TOTAIS DE VALIDAÇÃO OMITIDAS E INCLUÍDAS PARA AS IMAGENS DE TREINO E DE TESTE	133
TABELA 8.8 - EXATIDÃO DO UTILIZADOR E PRODUTOR (%) E COEFICIENTE DE CONCORDÂNCIA <i>KAPPA</i> PARA A IMAGEM DO TESTE DE PROJEÇÃO	135
TABELA 8.9 - ERROS DE COMISSÃO (%) PARA A IMAGEM DO TESTE DE PROJEÇÃO	135
TABELA 8.10 - ERROS DE OMISSÃO (%) PARA AS IMAGENS DO TESTE DE PROJEÇÃO	136
TABELA 8.11 - CONTAGEM DO NÚMERO DE AMOSTRAS TOTAIS DE VALIDAÇÃO OMITIDAS E INCLUÍDAS PARA O TESTE DE PROJEÇÃO	137

Lista de siglas e acrónimos

ACP	Análise por Componentes Principais
ACEL	Associação das Empresas Produtoras de Pasta de Celulose
ASTER	<i>Advanced Spaceborne Thermal Emission and Reflection Radiometer</i>
Bit	<i>Binary Digit</i>
CASI	<i>Compact Airborne Spectrographic Imager</i>
CELPA	Associação Nacional da Indústria Papeleira
CIG	Ciência de Informação Geográfica
CLC	<i>CORINE Land Cover</i>
CNES	<i>Centre National d'Études Spatiales</i>
CNIG	Centro Nacional de Informação Geográfica
COS	Carta de Ocupação do Solo de Portugal
CP	Componentes Principais
DEM	<i>Digital Elevation Models</i>
DGF	Direção Geral das Florestas
DGRF	Direção Geral dos Recursos Florestais
DGT	Direção Geral do Território
DOI	<i>Department of Information</i>
DR	Deteção Remota
EBBI	<i>Enhanced Built-Up and Bareness Index</i>
EC	Erro de Comissão
EDC	<i>EROS Data Center</i>
EEA	<i>European Environment Agency</i>
EG	Exatidão Global
Envisat	<i>Environmental Satellite</i>
EO	Erro de Omissão
EOSAT	<i>Earth Observation Satellite Company</i>
EP	Exatidão do Produtor
EROS	<i>Earth Resources Observation Satellites</i>
ERS-2	<i>European Remote Sensing</i>
ERTS	<i>Earth Resources Technology Satellites</i>
ESA	<i>European Space Agency</i>
ETM	<i>Enhanced Thematic Mapper</i>

ETM +	<i>Enhanced Thematic Mapper Plus</i>
ETRS	<i>European Terrestrial Reference System</i>
EU	Exatidão do Utilizador
Eurostat	Gabinete de Estatísticas da União Europeia
FAO	<i>Food and Agriculture Organization</i>
GEOBIA	<i>Geographic Object Based Image Analysis</i>
GLC	<i>A Global Land Cover</i>
GOFC-GOLD	<i>Global Observation of Forest and Land Cover Dynamics</i>
I&CLC	<i>Image & CORINE Land Cover</i>
ICNF	Instituto de Conservação da Natureza e Florestas
IFN	Inventário Florestal Nacional
IFOV	<i>Instantaneous field of view</i>
IGBP	<i>International Geosphere-Biosphere Programme</i>
IGP	Instituto Geográfico Português
IIASA	<i>International Institute for Applied Systems Analysis</i>
INSPIRE	<i>Infrastructure for Spatial Information in the European Community</i>
IRS	<i>Indian Remote Sensing</i>
IV	Infravermelho
IVOC1	Infravermelho de comprimento de onda curto 1 (SWIR 1 na sigla inglesa)
IVP	Infravermelho Próximo (NIR na sigla inglesa)
IVT1	Infravermelho Térmico 1 (TIRS 1 na sigla inglesa)
JRC	<i>Joint Research Centre</i>
Landsat	<i>Land Remote Sensing Satellite</i>
LCCS	<i>Land Cover Classification System</i>
LDCM	<i>Landsat Data Continuity Mission</i>
LIDAR	<i>Light Detection and Ranging</i>
LNEC	Laboratório Nacional de Engenharia Civil
Matlab	<i>Matrix Laboratory</i>
MDT	Modelo Digital do Terreno
MERIS	<i>Medium Resolution Imaging Spectrometer</i>
MSS	<i>Multispectral Scanner</i>
MSSe	<i>Multi Scale Segmentation</i>
NASA	<i>National Aeronautics and Space Administration</i>
NDVI	<i>Normalized Difference Vegetation Index</i>

NDWI	<i>Normalized Difference Water Index</i>
NOAA	<i>United States National Oceanographic and Atmospheric Administration</i>
NPP	<i>Net Primary Production</i>
NR	Níveis Radiométricos
NUT	Nomenclatura das Unidades Territoriais
OBIA	<i>Object-Based Image Analysis</i>
OLI	<i>Operational Land Imager</i>
OLR	<i>One Level Representation</i>
ORM	<i>Object Related Modelling</i>
Pan	Pancromática (banda 8 do satélite Landsat 8)
PROF	Planos Regionais de Ordenamento Florestal
RBV	<i>Return Beam Vidicon</i>
SAR	<i>Synthetic Aperture Radar</i>
SEASAT	<i>Sea Surveillance Satellite</i>
SIG	Sistemas de Informação Geográfica
SPOT	<i>Satellite Pour l'Observation de la Terre</i>
SVH	Sistema Visual Humano
TBFRA	<i>Temperate and Boreal Forest Resources assesment</i>
TIRS	<i>Thermal Infrared Sensor</i>
TM	<i>Thematic Mapper</i>
UCL	Université Catholique de Louvain
UMC	Unidade Mínima Cartográfica
UN	<i>United Nations</i>
UNEP	<i>United Nations Environment Programme</i>
USGS	<i>United States Geological Survey</i>
V	Vermelho (banda 4 do satélite Landsat 8)
VAC	Variáveis com Alta Correlação
VD	Verde (banda 3 do satélite Landsat 8)

Agradecimentos

A concretização deste trabalho teve o contributo de inúmeras pessoas às quais não posso deixar de agradecer.

Primeiramente um grande agradecimento ao meu orientador Professor Doutor Fernando Jorge Rocha não só pela orientação e acompanhamento, mas também por todo o apoio e ajuda crucial no desenvolvimento do trabalho.

De seguida, agradeço à minha coorientadora Engenheira Ana Fonseca pela oportunidade de estágio que me proporcionou. Este agradecimento estende-se ainda ao Laboratório Nacional de Engenharia Civil, instituição de acolhimento onde foi realizado todo o trabalho prático reportado desta dissertação, bem como o ensinamento de novas metodologias de trabalho. Um especial agradecimento à Dora Roque por toda a ajuda que me facultou e dispêndio de tempo no ensinamento de novas ferramentas de trabalho.

Por fim, agradeço também a todos os meus familiares e amigos que me acompanharam direta e indiretamente ao longo do período em que este trabalho decorreu.

Capítulo 1 - Introdução

A detecção remota (DR) é a ciência que permite obter informação sobre objetos, áreas ou fenómenos, através da análise de dados adquiridos por aparelhos de observação (sensores) sem contacto físico com os mesmos, sendo usada para “(...) medir e monitorizar importantes características biofísicas e atividades humanas da Terra” (Jensen, 2000). Segundo Bariou (1978) “(...) a detecção remota agrupa um conjunto de técnicas capazes de fornecer, à distância, as informações relativas a um objeto, utilizando o conhecimento sobre a emissão e reflexão das radiações eletromagnéticas¹, desde os comprimentos de onda ultravioletas às micro-ondas”. Deste modo, numa perspetiva mais lata, entende-se por detecção remota um encadeamento de processos, composto essencialmente pela aquisição, transmissão, armazenamento, processamento e visualização de dados geográficos numéricos em formato matricial.

Desde o início da década de 1970 que a detecção remota se tem desenvolvido, com o objetivo de alcançar, como qualquer outra técnica baseada na computação, a automatização. Ao contrário da técnica de interpretação visual (classificação qualitativa), a classificação com base computacional (classificação quantitativa) permite obter resultados de forma rápida e relativamente fácil (Crosta, 1993). Porém, apesar de um observador humano conseguir facilmente diferenciar e categorizar uma imagem em classes de interesse (Marpu *et al.*, 2008), esta realidade dificilmente é reproduzida com a mesma qualidade ao fazer uso do computador e dos métodos de processamento (semi)automático. Assim, pretende-se que as técnicas de classificação automática repliquem os métodos e a eficiência da classificação por fotointerpretação, com base em algoritmos de visão computacional.

No entanto, os programas capacitados para este tipo de função (visão computacional), necessitam de tempo para serem desenvolvidos, e requerem

¹ A energia eletromagnética pode ser caracterizada em função da localização dos comprimentos de onda no espectro eletromagnético, assumindo especial importância na região do visível (0,4 a 0,7 μm), do infravermelho (0,7 a 14 μm) e micro-ondas (1 mm a 1 m).

especialistas dotados e dispostos a programar e tentar decodificar o Sistema Visual Humano (SVH) de forma a conseguir uma aproximação o mais fidedigna possível. Como resultado, estes programas tornaram-se caracteristicamente mais lentos a processar os dados e complexos na sua operacionalização. Mais importante ainda, são direcionados (e, portanto, demasiado ajustados) para tarefas específicas, tornando-se inadequados quando é feita uma modificação (mesmo que ligeira) em algum parâmetro, “(...) como a alteração da resolução espacial, tipo de imagem, ocupação do solo, área geográfica ou estação do ano” (Opitz e Blundell, 2008).

De forma a colmatar algumas das falhas existentes nas várias técnicas de deteção remota, adaptando as mesmas à realidade, muitos investigadores desenvolveram uma nova abordagem de imagens conhecida como *Object-Based Image Analysis* (OBIA). A análise de imagens baseada em objetos é uma metodologia prometedora pois apresenta-se como “(...) uma forma de deteção remota que pretende modelar a habilidade da capacidade visual humana para interpretar uma imagem” (Corcoran e Winstanley, 2008). Esta abordagem revela-se capaz de explorar todos os aspetos da deteção remota, desde propriedades contextuais, espaciais, espectrais, temporais, texturais e também hierárquicas, permitindo a interpretação de classes de complexa extração.

A quantidade de literatura disponível sobre OBIA tem vindo a aumentar, na medida em que podemos agora observar subtópicos emergentes, tais como conceitos de hierarquia e escala específicos para OBIA (Addink *et al.*, 2007), segmentação (Neubert *et al.*, 2008; Trias-Sanz *et al.*, 2008; Weidner, 2008), deteção de alterações (Bontemps *et al.*, 2008; Weinke *et al.*, 2008; Gamanya *et al.*, 2009) e avaliação de exatidão (Albrecht, 2008; Platt e Rapoza, 2008; Grenier *et al.*, 2008). As fronteiras de pesquisa têm-se claramente expandido e, portanto, os investigadores tiveram de aumentar o seu grau de especialização. As aplicações em OBIA desenvolveram-se ainda mais rapidamente desde 2004 - 2005 e recentemente têm sido publicados vários livros sobre este tema (Blaschke *et al.*, 2008; Nussbaum e Menz, 2008).

Uma das tendências mais recentes é a de os métodos OBIA se tornarem parte de fluxos de trabalho dedicados e convergirem com as principais aplicações de Sistemas de Informação Geográfica (SIG) (Baatz *et al.*, 2008). Este corpo crescente de literatura

científica transmite uma sensação de otimismo de que os métodos OBIA geram uma importante informação geoespacial multi-escala, por vezes travada pela percepção de que os conjuntos de regras de classificação e os fluxos de trabalho cada vez mais complexos levantam pelo menos tantas questões de investigação como as que resolvem.

Há uma percepção que a maior resolução e o detalhe de deteção disponíveis recorrendo a instrumentos óticos melhorados como o Radar, o *Light Detection and Ranging* (LiDAR), ou mesmo o Sonar (Lucieer, 2008) criam problemas à abordagem tradicional (*i.e.*, píxel-a-píxel) de elaboração de cartografia de uso e ocupação do solo. A OBIA suporta as tentativas de superar a visão centralizada da ocupação do solo, que é limitada a uma categorização puramente descritiva das características espectrais dos píxeis e abre caminho para um uso combinado de informações espectrais e espaciais (contextuais), no sentido de desenvolver indicadores de uso e ocupação do solo.

Apesar de até há alguns anos atrás os utilizadores terem instado a indústria no sentido de se obter imagens de maior resolução espacial, atualmente temos evidências de uma complexidade crescente e de cada vez mais utilizadores clamando pela simplificação ao invés do contínuo aumento das resoluções espaciais. Cada vez menos especialistas acreditam que as novas melhorias na resolução espacial dos sensores a bordo dos satélites podem produzir melhores resultados.

Atualmente os objetos não são apenas o foco de tarefas analíticas como o processamento de imagem, mas fazem parte de uma discussão mais abrangente, que inclui os aspetos ontológicos e epistemológicos dos objetos, bem como os seus métodos de derivação. Se considerarmos a análise de dados provenientes de deteção remota como um subconjunto da análise espacial podemos referir-nos a Goodchild e Longley (1999), que definiram a análise espacial como “(...) um subconjunto de técnicas analíticas cujo resultado depende do enquadramento, ou vai mudar se o enquadramento muda ou se objetos são reposicionados dentro dele”. Como as considerações sobre dos aspetos epistemológicos e ontológicos de objetos do mundo real estão para além dos objetivos desta dissertação referenciam-se apenas trabalhos anteriores sobre o a dupla identidade dos objetos da paisagem, onde estes são um contentor para todos os tipos de objetos do mundo real, incluindo os espaços artificiais

que por vezes são tratados separadamente. Assim, para a discussão ontológica, sugere-se o trabalho de Gahegan (1999). Burnett e Blaschke (2002) enfatizam que os objetos são apenas a nossa (humana) discretização de estruturas hierárquicas quase-decomponíveis (Koestler, 1967) e criaram o termo “dicotomia objeto/não-objeto”.

A natureza e o ritmo de desenvolvimento técnico em detecção remota tem sido, e continua a ser, impressionante, ainda que, se o objetivo é contribuir significativamente para a monitorização ambiental, para o suporte à tomada de decisões e a processos de planeamento racionais, as questões conceituais são de muito mais importância do que as semânticas. Blaschke *et al.* (2008), ao explicarem esta evolução tecnológica orientada para o utilizador na análise de imagens de detecção remota, e como ele se desenrola dos píxeis para objetos, afirmam que a OBIA é fortemente direcionada para explorar o desenvolvimento orientado para aplicações.

A análise elaborada no contexto desta dissertação reforça a conclusão de que a primeira fase do desenvolvimento da OBIA foi principalmente dedicada ao *software*, aos algoritmos e à infraestrutura necessária para gerar e explorar objetos. Hoje, o objetivo último, presente em cada vez mais literatura e aplicações não se encontra focado na construção de melhores métodos de segmentação, mas sim em incorporar e desenvolver a inteligência geográfica, *i.e.*, informações apropriadas dentro de um contexto geográfico, e tudo o que está implícito para alcançar este objetivo. Lang (2008) refere-se a este tópico como “informação condicionada”.

A última fase de investigação em OBIA (desde 2005) tem sido mais dirigida para a automatização do processamento de imagens. Como consequência da crescente proliferação de imagens de alta e muito alta resolução espacial e das melhorias no acesso a essas imagens, cada vez mais artigos, se centram na temática da delimitação automática de objetos. Certamente que o reconhecimento automatizado de objetos é um objetivo final, mas realisticamente na atualidade este é quase sempre alcançado de forma gradual, com procedimentos fortemente interligados, seja através da construção de fluxos de trabalho ou com claras quebras nesses mesmos fluxos. Em ambos os casos, as etapas envolvem abordar várias instâncias multi-escala de objetos relacionados dentro de uma única imagem (*e.g.* copas individuais das árvores, *clusters* de árvores, e florestas).

Também se podem encontrar vários artigos que lidam com o reconhecimento de objetos e a extração de características, mas que, embora intrinsecamente vinculados à OBIA, na maioria dos casos estes pontos não são um fim em si mesmos. As técnicas de segmentação de imagem advêm da década de 1980, com ênfase no processamento de imagens industriais (Haralick e Shapiro, 1985; Pal e Pal, 1993) e, em menor medida, nas aplicações geoespaciais. Nos últimos anos temos assistido a um aumento do número de aplicações que usam sistematicamente informação proveniente de detecção remota como um *proxy* para fenômenos ou processos.

Um caminho para a investigação lógica é a da obtenção de dados de uso e ocupação do solo através da incorporação de informações contextuais dentro da imagem. A informação espacial em imagens inclui aspetos como a textura da imagem, informações contextuais, proximidade entre os píxeis e atributos geométricos dos objetos (Tiede *et al.*, 2008; Aubrecht *et al.*, 2008; Van der Werff e van der Meer, 2008). É cada vez mais reconhecido que a informação espacial acerca dos objetos - especialmente informação de contexto - pode ser tornada explícita quando os píxeis estão vinculados a objetos (Burnett e Blaschke, 2003). Este passo envolve necessariamente pelo menos duas dimensões da escala: (i) escala absoluta quando se aponta para objetos específicos como árvores isoladas, casas simples, floresta, ou corpos de água e (ii) escala relativa em relação à resolução dos dados. As medições baseadas em SIG, do tamanho, forma, compacidade, alongamento, retangularidade, etc., dos polígonos são genéricas, o que justifica o recurso a *software* especializado. Uma vez que a escala pode ser considerada como uma “janela da percepção” (Marceau, 1999) ou uma função (Strahler *et al.*, 1986), normalmente as aplicações precisam de uma escala base. Muitos dos artigos publicados na literatura científica abordam somente uma escala, ou colocando de forma diferente, muitos problemas de planeamento territorial estão associados a uma determinada escala. Por exemplo, van der Werff e van der Meer (2008), demonstraram a mais-valia da utilização de medidas de forma como informação complementar para classificar corpos de água morfologicamente diferentes.

Burnett e Blaschke (2003) desenvolveram uma metodologia para derivar objetos simultaneamente em vários níveis e utilizar essa informação numa classificação. Os

autores batizaram este processo de modelação baseada em segmentação/objetos multi-escala (*Multi Scale Segmentation/Object Related Modelling* [MSSe/ORM]). No entanto, Lang e Langanke (2006) mostraram que para casos específicos um nível de representação (*One Level Representation* [OLR]) pode ser suficiente e mais linear/simples. Em ambos os casos, a base é a delimitação de áreas relativamente homogéneas, e o denominador comum de várias aplicações de OBIA é o objetivo de derivar “objetos significativos”. As diferenças residem principalmente na forma como são estabelecidos os objetos a vários níveis de dissecação da realidade. Hay e os seus colaboradores (Hay *et al.*, 2005; Hall *et al.*, 2004; Castilla e Hay, 2006; Castilla *et al.*, 2008) desenvolveram passo-a-passo uma metodologia de aumento de escala (*upscaling*) para objetos específicos. Uma questão específica sobre a operacionalização deste objetivo é se, os objetos pertencentes a vários níveis, são ou não, geometricamente construídos um após o outro, ou se os diferentes processos de segmentação funcionam independentemente levando a limites que se encaixam perfeitamente (*cf.* Castilla *et al.*, 2008). Uma vez que a escala adequada de observação varia em função do tipo de ambiente e dos objetivos (Marceau, 1999; Hay *et al.*, 2001), a seleção da escala de trabalho é um tópico muito importante, suscitando grande interesse na atual investigação em OBIA.

Outro tema, não menos importante no contexto da investigação em OBIA, é o da reprodutibilidade metodológica. Walker e Briggs (2007) desenvolveram uma abordagem de classificação que Walker e Blaschke (2008) converteram num conjunto de regras reprodutível. Schöpfer e Möller (2006) demonstraram a possibilidade de reprodutibilidade dos métodos OBIA para várias áreas metropolitanas. No entanto, se esta reprodutibilidade direta é relativamente fácil de alcançar, já a reprodutibilidade indireta, *e.g.* identificação de um objeto inalterado entre duas datas de forma igual nas duas imagens, permanece como um dos principais *Hot Spots* da investigação em OBIA. Estas questões estão na base da escolha do tema desta dissertação.

1.1. Objetivos

Numa perspetiva de contribuição e continuidade aos desenvolvimentos feitos na área científica da OBIA, o Laboratório Nacional de Engenharia Civil (LNEC) propôs um tema de estágio com o intuito de dar continuidade a um trabalho anteriormente realizado (Roque *et al.*, 2014). Nesse trabalho foi desenvolvido um método, baseado na análise por componentes principais (ACP), que permite o ajuste automático dos limiares adequados para a classificação de imagens da mesma área geográfica, mas de épocas diferentes. O algoritmo desenvolvido foi testado em imagens *Synthetic Aperture Radar* (SAR) adquiridas pelos satélites *Environmental Satellite* (Envisat) e *European Remote Sensing-2* (ERS-2) e apenas foi aplicado à identificação de áreas inundadas.

No presente trabalho a metodologia foi melhorada e adaptada para imagens óticas do sensor Landsat 8, com o intuito de classificar semiautomaticamente os objetos relativos à ocupação do solo em imagens adquiridas em épocas diferentes. Desta forma, o presente trabalho tem os seguintes objetivos:

- ◆ Desenvolver uma metodologia de classificação multitemporal;
- ◆ Construir um algoritmo de classificação baseada em objetos aplicável a imagens com datações diferentes da mesma área de estudo;
- ◆ Determinar semiautomaticamente os limiares mais adequados para cada imagem através da Análise de Componente Principais;
- ◆ Avaliar a capacidade da metodologia criada de originar cartografia temática, neste caso de ocupação do solo;
- ◆ Por fim, pretende-se fundamentalmente que seja feito um avanço na área da deteção remota e no processamento digital de imagens.

1.2. Organização da dissertação

A presente dissertação é estruturada em 9 capítulos. No primeiro capítulo é feito um breve enquadramento da temática em estudo, são apresentados os objetivos e a forma como esta dissertação foi organizada.

No segundo capítulo são definidos os conceitos de uso e ocupação do solo e descritos os sistemas e métodos de classificação cartográfica. Logo de seguida, no terceiro capítulo é produzida uma reflexão sobre as nomenclaturas de uso do solo disponíveis para Portugal continental.

No quarto capítulo é feita uma revisão de literatura sobre detecção remota com especial incidência nos processos de segmentação e no quinto capítulo explana-se a classificação de imagens baseada em objeto, sendo descrito o conceito de objeto e os processos de segmentação e classificação de imagens.

No sexto capítulo é apresentada a unidade espacial em análise e feito um breve enquadramento da mesma em termos administrativos e de ocupação do solo. São descritos os dados e materiais necessários para a elaboração deste trabalho, nomeadamente uma breve apresentação das imagens Landsat 8 e dos programas informáticos (*software*) utilizados.

No sétimo capítulo é apresentada a metodologia de classificação multitemporal. Primeiramente é descrita a construção do algoritmo de classificação das imagens de treino, as variáveis utilizadas e os respetivos limiares de corte das funções. De seguida, procede-se ao cálculo semiautomático dos limiares de cortas das funções das imagens de teste através da ACP, e é feito o teste à sensibilidade da metodologia de classificação multitemporal.

No oitavo capítulo são apresentados e analisados os resultados obtidos, sendo feita uma avaliação da exatidão, dos erros de comissão e omissão e por fim do coeficiente de concordância *Kappa* da cartografia resultante.

Por fim, o nono capítulo apresenta as conclusões relativas ao trabalho efetuado, em função dos objetivos propostos e descreve desempenho da metodologia desenvolvida.

Capítulo 2 - Uso e ocupação do solo

Stewart (1968) refere que o termo terra, *i.e.*, solo, é usado em sentido compreensivo, integrador referindo-se a um vasto espectro de atributos de recursos naturais num perfil vertical que vai desde a atmosfera até alguns metros abaixo da superfície. Por outro lado, Hoover e Giarratani (1984), denotando uma perspectiva mais economicista afirmam que solo, em princípio, indica espaço.

O conceito de uso do solo está unido à noção de espaço territorial, visto que é entendido como uma área perfeitamente referenciada pelo valor que lhe atribuímos. São várias as definições que existem para designar os termos solo, ocupação do solo e uso do solo, as quais variam com a finalidade e o contexto em que são utilizadas (Briassoulis, 2000).

Os termos ocupação do solo e uso do solo, embora por vezes utilizados como sinónimos, possuem significados diferentes. As suas definições variam de acordo com a aplicação e o âmbito em que são aplicados, como também variam com as prioridades conferidas aos atributos que caracterizam o solo. Para a definição de uma nomenclatura comum, é importante compreender as diferenças entre eles.

O primeiro (ocupação) identifica e classifica as entidades físicas presentes na superfície terrestre e o segundo (uso), a utilização dada a essas mesmas entidades físicas.

Segundo Turner *et al.* (1995) a ocupação do solo descreve o estado físico da superfície como o tipo e a quantidade de vegetação, materiais terrestres, e consequentes estruturas humanas, como edifícios e pavimentos, assim como outros aspetos do meio físico (Briassoulis, 2000; Malczewski, 2003). O uso do solo, por outro lado, corresponde à utilização dada a uma determinada ocupação do solo (Malczewski, 2003). O uso do solo envolve a forma como o solo é manipulado e o propósito subentendido a essa manipulação, *i.e.*, a finalidade para a qual o solo é usado (Turner *et al.*, 1995). Assim, a morfologia do uso do solo varia consoante o seu propósito (Briassoulis, 2000).

Resumindo, o uso do solo traduz o destino que o Homem dá à terra (Turner e Meyer, 1994). Skole (1994) afirma que “(...) uso do solo é a utilização humana de uma certa ocupação do solo, o meio pelo qual a atividade humana se apropria dos resultados da produção primária líquida (*Net Primary Production* [NPP]) conforme determinado por um complexo conjunto de fatores socioeconómicos.” Finalmente, a *Food and Agriculture Organization (FAO)/International Institute for Applied Systems Analysis (IIASA)* (1993) afirma que o uso do solo diz respeito à finalidade para a qual o solo é usado pela população humana local, a qual pode ser definida como as atividades humanas que estão diretamente relacionadas com a terra, fazendo uso de seus recursos ou tendo impacto sobre eles.

Face ao anteriormente descrito, é lícito afirmar-se que quem elabora a carta de uso do solo se encontra na dimensão do espaço territorial socialmente referenciado (Pardal, 1988). Ou seja, existe uma conexão à carga social (e económica) associada à noção de território; só existe uso do solo quando existe uma sociedade organizada; caso contrário, falar-se-á de ocupação do solo, que não implica “usufruto” dos espaços funcionais (na aceção mais lata do termo).

Assim, considera-se que a designação de uso do solo induz a noção de combinação geográfica, privilegiando-a face à análise dos aspetos físicos como fenómenos isolados. Esta última noção é o resultado da associação espaço físico (*e.g.* hidrografia, topografia, morfologia, uso do solo) - espaço social (*e.g.* vertentes económica, residencial, cultural, e de lazer), aproximando-se da conceção de espaço funcional, quando interpretado à luz da maneira como funciona e não pelo que lá existe.

Entre um e outro tipo de cartas existe uma relação estreita entre as entidades identificadas e classificadas, na medida em que algumas classes de uso são deduzidas das classes de ocupação (*e.g.* a classe de uso “Florestal” extraída das classes de “Pinheiro”). Contudo, para outras classes a linearidade da relação fica esbatida, uma vez que as entidades físicas semelhantes poderão corresponder diferentes tipos de uso (*e.g.* classe de ocupação “Edifícios” e das classes de uso “Habitação” e “Serviços”). Neste último caso, para a diferenciação do uso, ter-se-ão de acrescentar aos atributos físicos da classe, outros atributos que exprimam, por exemplo, a relação entre a localização da entidade e a sua função no contexto espacial. Deste modo, e como a

deteção remota é um processo de deteção física, pode-se concluir que a inferência da ocupação do solo é muito mais direta (linear) que a do uso do solo (Dobson, 1993; Webster, 1996; Bibby e Shepherd, 1999).

O uso do solo é, assim, a representação de uma realidade complexa, com a qual se pretende identificar objetos e atribuir significados às funções de unidades de espaço (aqui entendidas como território). Para Briassoulis (2000), a sua mudança/alteração (do uso do solo) implica transformações quantitativas na área (acréscimo ou decréscimo) de um determinado uso do solo. Segundo Jones e Clark (1997), estas transformações/alterações podem envolver: *i*) mudança de um uso para outro, ou *ii*) modificação de um uso, como por exemplo aquando das alterações de status das áreas residenciais de alto para baixo padrão, sem que se registe alteração física ou quantitativa dos edifícios.

A riqueza que advém dos diversos ensaios teóricos sobre esta temática revela como as diferentes disciplinas teorizam e modelam as mudanças de uso e ocupação do solo (Briassoulis, 2000). As consequências destas vicissitudes, no que à deteção remota diz respeito, são:

- ◆ A exatidão das classificações urbanas é claramente mais pobre do que a obtida em áreas não urbanas. Tanto em termos semânticos, *i.e.*, número de classes que podem ser individualizadas, como classificatórios, *i.e.*, a exatidão com que essas classes são identificadas;
- ◆ As tipologias de uso do solo que podem ser obtidas podem ser diferentes das nomenclaturas funcionais utilizadas na análise urbana.

Numa tentativa de sistematização do conhecimento, vários autores definem, de uma forma geral, o uso e ocupação do solo como:

- ◆ **Ocupação do solo** – a ocupação do solo está relacionada com os tipos de elementos presentes na superfície terrestre (Lillesand e Kiefer, 2000); relaciona-se com a natureza física ou forma da superfície terrestre, e pode ser visualmente identificado por técnicas de observação ao solo tradicionais ou por técnicas de deteção remota (Mather, 1986).

- ◆ **Uso do solo** – relacionado com a atividade humana associada a uma parte específica do território (Lillesand *et al.*, 2003); é o produto da decisão humana (Mather, 1986).

Embora as definições apresentadas procurem, de uma forma geral, caracterizar as duas noções apresentadas, a verdade é que escondem uma temática bastante mais complexa, quer ao nível teórico quer ao nível prático. Assim, as noções de uso e/ou ocupação do solo podem caracterizar-se genericamente por três componentes:

- i. Forte heterogeneidade, ao nível da forma e da função dos objetos constituintes do espaço;
- ii. Forte especificidade, na triangulação entre a forma, função e contexto espacial;
- iii. Forte complexidade, resultante da relação simultânea entre heterogeneidade e especificidade, ao nível das inter-relações entre elementos constituintes do espaço, nomeadamente com a introdução de hierarquias de funções.

A forte heterogeneidade dos objetos revela-se, por um lado, na diversidade das formas e materiais existentes (num sentido físico dos mesmos) e, por outro, na diversidade de funções inerentes a essas mesmas formas e materiais, quando interpretadas à luz do seu uso social num dado território. A organização territorial dos elementos e funções, isto é, a sua organização espacial é traduzida pelas relações espaciais entre elas, podendo ser de diferentes graus e origens. Ou seja, por exemplo, a geometria ou desenho de uma determinada área urbana determina as características de circulação de trânsito e indivíduos. Da mesma forma, a proximidade entre o tipo e número de atividades/funções existentes, e suas inter-relações, podem originar dependências de hierarquia, com uma atividade superior a determinar a existência ou não de atividades de nível inferior.

Porém, o problema da complexidade do uso e ocupação do solo assume maiores proporções quando o objetivo é o de obter uma classificação de uso do solo e não de ocupação do solo. A complexidade inerente a esta temática parece dar origem a um paradoxo entre as alíneas *i)* e *ii)* – *i.e.*, o uso do solo é simultaneamente heterogéneo e específico. Contudo, este é explicável pelas relações existentes entre os diferentes

elementos, quer ao nível da forma, quer ao nível da função, que inseridas em determinado contexto espacial adquirem propriedades específicas. Por exemplo, as relações de dependência entre a função habitação e a função indústria serão certamente diferentes, consoante o tipo de espaço em análise.

2.1. Sistemas de Classificação

Os sistemas de classificação são ferramentas que descrevem determinados aspetos do terreno. Existem vários termos que lhes estão associados que são utilizados de forma ambígua. Os termos que mais se confundem são a classificação, a nomenclatura e a legenda (Gabinete de Estatísticas da União Europeia [Eurostat], 2000).

O conceito de classificação (Sokal, 1974) define-se como a organização de objetos em grupos com base na sua relação. Contudo, o processo de classificar todos os objetos não inclui o modo de identificação desses mesmos objetos nem o processo de atribuição de nomes aos grupos. Portanto, a classificação requer uma definição dos limites das classes, que deve ser clara, precisa, possivelmente quantitativa e com base em critérios objetivos. A classificação deve ser independente da escala, *i.e.*, as classes devem ser aplicáveis em qualquer escala ou nível de detalhe, e independente da fonte, implicando que é independente dos meios utilizados para recolher a informação. A classificação é uma representação abstrata da realidade, utilizando critérios de diagnóstico bem definidos, designados de classificadores.

Por outro lado, a nomenclatura é uma lista de categorias e o processo de atribuição de nomes a essas categorias/classes, processo esse que engloba um conjunto de regras para a aplicação dos respetivos nomes. Quanto à legenda, esta corresponde à aplicação de uma nomenclatura a um determinado propósito. Enquanto uma nomenclatura enumera todas as categorias que abrangem todos os objetos, a legenda corresponde a uma parte dessa lista. Algumas classes podem ser retiradas diretamente da nomenclatura, outras ficam omissas e outras ainda são combinadas de forma a gerar categorias complexas.

Assim, a legenda é dependente da escala e da representação cartográfica (por exemplo, a mistura de unidades cartográficas se os elementos que compõem essas

unidades forem muito pequenos para serem delineados de forma independente); e dependente dos dados e da metodologia de produção cartográfica (por exemplo, uma fotografia aérea mostra características diferentes de uma imagem de satélite).

Um sistema de classificação deve ser entendido um processo que engloba quatro etapas:

- I. A demarcação do universo de entidades ou domínio do sistema;
- II. A criação de uma classificação de todos os objetos do domínio resultando numa organização em categorias;
- III. A implementação de um sistema para atribuição de nomes e descrição das categorias;
- IV. Um procedimento para atribuir a cada objeto uma e só uma das categorias classificadas e nomeadas.

2.2. Métodos de Classificação

A classificação (ou identificação) pode ser realizada *a priori* ou *a posteriori*. No primeiro caso, as classes são abstrações das situações que realmente ocorrem. A abordagem é baseada nas definições das classes antes dos dados terem sido recolhidos. Isto significa que todas as categorias e/ou combinações possíveis são geradas de antemão. A Figura 2.1 apresenta um exemplo de um sistema muito geral de classificação *a priori* baseado em quatro classes (triângulos em branco e preto e círculos em branco e preto) que representam a situação vivida no terreno. Devido à generalização das classes, o utilizador é obrigado a integrar o melhor possível as centenas de possibilidades do terreno numa das quatro classes, o que pode resultar na seleção de uma classe que não representa bem a situação real.

Este método é muito utilizado sendo a sua principal vantagem o facto de as classes serem normalizadas, independentemente da área de aplicação ou dos métodos utilizados para a recolha dos dados. A desvantagem é que se trata de um método rígido, *i.e.*, algumas situações reais por terem menor representatividade podem não ser facilmente atribuídas a uma determinada classe predefinida, ou no sentido inverso,

seria necessária uma grande quantidade de classes predefinidas para precaver todas as possíveis situações.

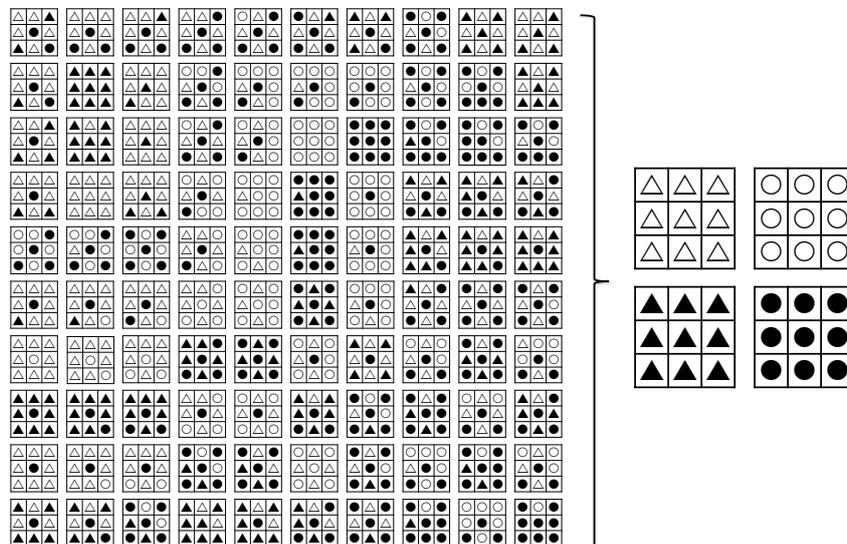


Figura 2.1 - Exemplo de um sistema de classificação *a priori* relativamente a uma situação concreta no terreno (adaptado de Kuechler e Zonneveld, 1988)

Esta solução para além de dificultar o trabalho do produtor e do utilizador pelo vasto leque de nomes e definições de classes, iria ainda dificultar a normalização, uma vez que o aumento do número de classes seria assente em ligeiras diferenças entre elas, o que originaria que cada utilizador pudesse ter uma interpretação diferente de cada classe. O sistema de classificação *a priori* entra assim num ciclo vicioso. Por um lado, o uso deste tipo de classificação como ferramenta para a normalização, obriga a englobar inúmeros tipos de uso e ocupação do solo num número limitado de classes mais genéricas, enquanto por outro lado, a tentativa de criar mais classes aumenta os problemas de normalização (Figura 2.2).

A classificação *a posteriori* difere da sua congénere pela sua abordagem direta e livre de preconceitos. Baseia-se na aplicação de uma combinação de códigos, escolhida de acordo com a realidade a classificar. A vantagem deste método é a sua flexibilidade quando comparado com a rigidez das classificações *a priori*. Esta abordagem implica um mínimo de generalização e adapta-se melhor a uma área específica. No entanto, uma vez que depende das condições específicas da área a que se aplica, perde a capacidade

de definir classes normalizadas, o que dificulta a comparação com outros produtos cartográficos (Di Gregorio e Jansen, 2000).

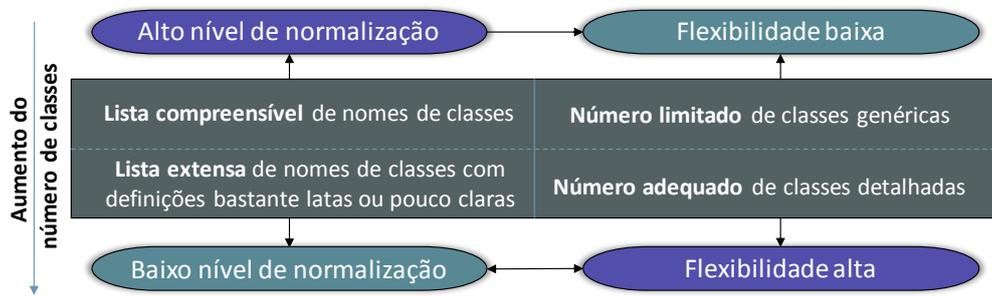


Figura 2.2 - Problemas das classificações *a priori* relativamente à sua flexibilidade

A Figura 2.3 apresenta um exemplo de um sistema de classificação *a posteriori*. As classes encaixam melhor na situação real do terreno, mas com a mesma quantidade de classes do sistema *a priori*, a área descrita é apenas uma porção do total.

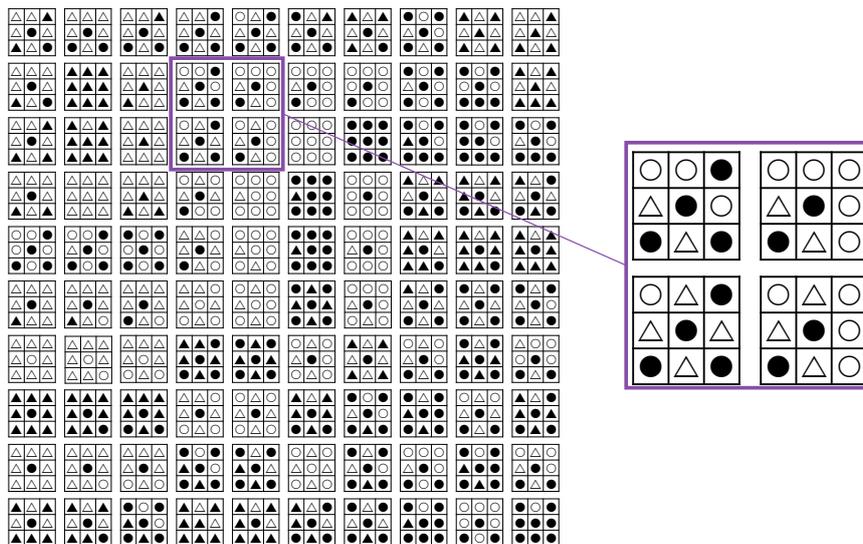


Figura 2.3 - Exemplo de um sistema de classificação *a posteriori* relativamente a uma situação concreta no terreno (adaptado de Kuechler e Zonneveld, 1988)

2.3. Sistemas hierárquicos e não-hierárquicos

Os sistemas de classificação podem-se dividir em hierárquicos e não-hierárquicos. O sistema hierárquico é o mais utilizado uma vez que garante maior

consistência devido à sua capacidade de englobar diferentes níveis de informação, começando num nível de classes que descrevem características mais gerais, e passando sucessivamente para níveis mais detalhados em que as primeiras classes se subdividem. Em cada nível as classes definidas são mutuamente exclusivas. No nível mais elevado são utilizados poucos critérios para definir as classes, enquanto nos níveis mais baixos o número de critérios aumenta (Figura 2.4). Os critérios utilizados num nível do sistema de classificação não devem ser repetidos nas definições das classes de um outro nível (Di Gregorio e Jansen, 2000). No entanto, este método apresenta desvantagens quando são necessárias alterações na estrutura hierárquica (Eurostat, 2000). Nessa altura, a única solução é a criação de novos níveis de detalhe para incluir as novas situações ou situações pouco frequentes, e esta solução poderá originar desequilíbrios dos sectores da estrutura hierárquica.

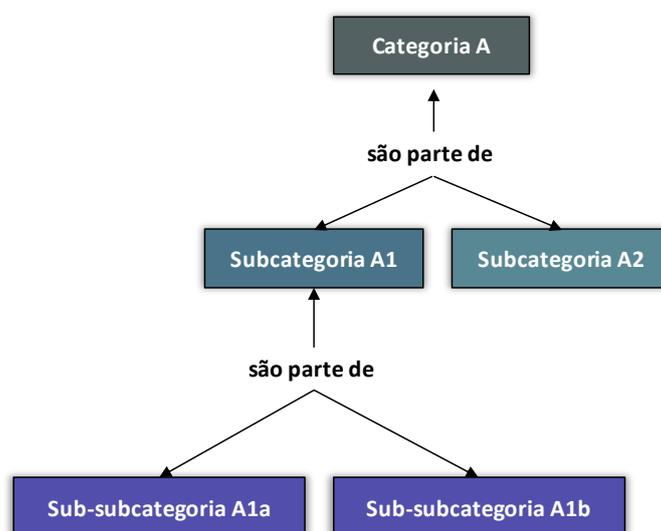


Figura 2.4 - Relações hierárquicas

Quanto aos sistemas não-hierárquicos, estes estão normalmente ligados à classificação *a posteriori*, já que não constituem uma estrutura rígida de organização das classes (Figura 2.5). Esta característica permite uma maior aproximação do sistema de classificação à realidade. No entanto, apresenta dificuldades de interpretação e de integração com outros sistemas de classificação. Existem algumas metodologias para a classificação de forma não-hierárquica. Radermacher (1988 citado por Eurostat, 2000), propõe a utilização de uma nomenclatura de ocupação do solo em conjugação com

uma de uso do solo, originando uma série de combinações das quais se excluem as que não apresentem significado, *e.g.* Água usada para floresta. As classes restantes constituiriam um sistema de classificação não-hierárquico.

Uma outra metodologia passível de utilização é o recurso a uma série de campos para descrever os objetos. Estes campos correspondem a características que os próprios objetos podem apresentar, e que uma vez identificadas permitem através das combinações resultantes descrever o objeto e agrupá-lo a outros similares. Ou seja, para classificar a ocupação do solo de uma determinada área o operador é confrontado com algumas opções em dois campos. No campo 1, deverá indicar a presença ou ausência de espécies florestais, enquanto no campo 2 deverá selecionar a partir de uma lista de espécies a que apresenta maior dominância. A combinação das opções selecionadas determina a classe de ocupação do solo naquela área.

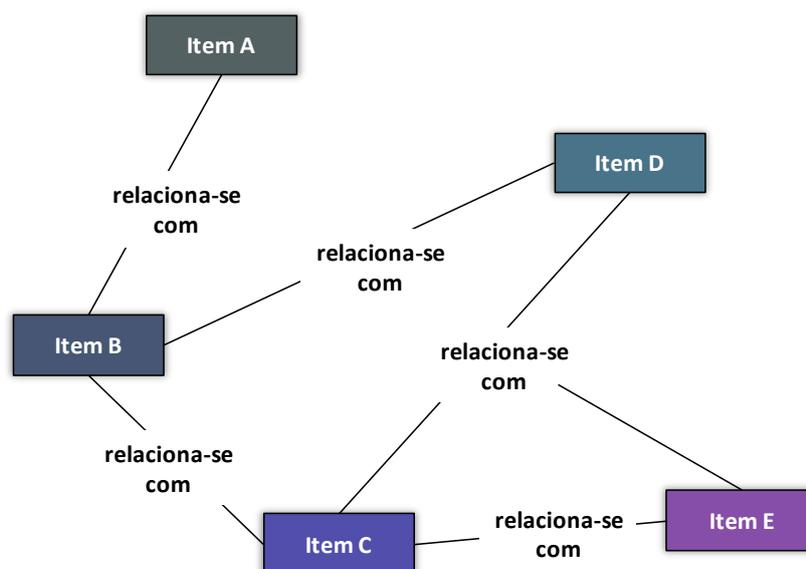


Figura 2.5 - Relações não-hierárquicas

A aplicação desta metodologia implica a seleção das possibilidades presentes em cada campo. Esta seleção é normalmente baseada num conjunto de regras que garantam a integridade da classificação, uma vez que não deverá ser possível ao operador indicar a ausência de uma classe no campo 1 e selecionar um subgrupo dessa mesma classe no campo 2.

Capítulo 3 - Nomenclaturas de Uso e Ocupação do Solo

A maioria das nomenclaturas usadas para cartografia ou estatísticas relacionadas com o espaço utiliza terminologias de uso do solo dirigidas para a compilação das atividades humanas. A construção de uma nomenclatura de uso e ocupação precisa de estar adequada para cartografar a diversidade do território considerado e deve ser compatível com a escala, o tamanho da unidade mínima cartográfica (UMC), a fonte de dados base e com as necessidades dos utilizadores.

Para se garantir a reprodução de resultados de um intérprete para outro, a terminologia necessita ser clara, precisa, não comportando um sentido vago, ou tão pouco ambíguo. Com base no estudo desenvolvido por Encarnação *et al.* (2004) apresenta-se, de forma comparada, uma síntese de alguns projetos/programas operacionais de cartografia de uso/ocupação do solo por meio de dados e técnicas de deteção remota, que envolvem o território nacional designadamente:

- ◆ A *Global Land Cover* (GLC);
- ◆ O Inventário *CORINE Land Cover* (CLC);
- ◆ O Inventário Florestal Nacional (IFN);
- ◆ A Carta de Ocupação do Solo de Portugal (COS).

3.1. Global Land Cover

O projeto *Global Land Cover 2000* (GLC2000) foi iniciado pela Comissão Europeia conjuntamente com o *Joint Research Centre* (JRC) com o propósito de criar um mapa global de ocupação do solo usando o sensor *Vegetation do Satellite Pour l'Observation de la Terre-4* (SPOT-4) (resolução espacial de 1165m x 1165m) que foi disponibilizado gratuitamente pelo *Centre National d'Études Spatiales* (CNES). O sistema de classificação do projeto (Di Gregorio e Jansen, 2000) baseia-se no *Land Cover Classification System* (LCCS) da FAO. A orientação e a metodologia são fornecidas pelo JRC. Após as classificações de áreas regionais e locais, realizadas por mais de 30 parceiros, o JRC integrou os resultados, finalizando o mapa global no final de 2002.

Em contraste com as iniciativas anteriores de cartografia global, o projeto GLC2000 é uma abordagem de-baixo-para-cima (*bottom-up*). Estiveram envolvidas neste projeto mais de 30 equipas de pesquisa, contribuindo para 19 sub-regiões de classificação. Havia duas condições a serem observadas pelos peritos regionais para garantir um certo grau de consistência, precisamente usar os dados SPOT e o sistema de classificação da FAO.

O facto de a cartografia ter sido realizada por peritos regionais tem uma série de benefícios. Em primeiro lugar, uma vez que cada perito regional tem um elevado nível de compreensão da sua região específica, pode ser garantido um determinado nível de qualidade. Em segundo lugar, cada parceiro tem a liberdade de aplicar os seus próprios métodos cartográficos e definir a sua própria legenda regional. Isso permite aos parceiros aplicar as técnicas de classificação que consideram mais adequados para a cartografia de ocupação do solo na sua região respetiva.

A continuação do projeto GLC2000 teve a designação de Globcover e foi desenvolvida pela Agência Espacial Europeia (*European Space Agency [ESA]*). O objetivo do projeto Globcover-ESA é a geração de um mapa mundial de ocupação do solo usando uma cadeia automatizada de processamento de séries cronológicas de dados do satélite *Medium Resolution Imaging Spectrometer (MERIS)*, com 300m de píxel. O projeto foi realizado por um consórcio internacional, começou em abril de 2005 e dependia do retorno (*feedback*) e comentários de um grande conjunto de parceiros, incluindo utilizadores finais pertencentes a instituições internacionais (JRC, FAO, *European Environmental Agency (EEA)*, *United Nations Environment Programme (UNEP)*, *Global Observation of Forest and Land Cover Dynamics (GOFC-GOLD)* e *International Geosphere-Biosphere Programme (IGBP)*, além de avaliação interna da ESA.

Os produtos Globcover encontram-se disponíveis para qualquer uso não comercial e são os seguintes: Mapa de ocupação do solo para o período de dezembro de 2004 a junho de 2006 (1 produto). Este mapa global de ocupação do solo é obtido através da classificação automática ajustada ao nível regional, de uma série temporal de imagens MERIS. São definidas 22 classes de ocupação do solo usando o sistema de classificação de ocupação do solo LCCS das Nações Unidas (*United Nations [UN]*); Mapa

regional de ocupação do solo para o período de dezembro de 2004 - junho de 2006 (11 produtos). Este conjunto de mapas também é obtido através da mesma classificação automática, ajustada a nível regional, e usando uma série temporal de imagens MERIS. No entanto, a tipologia de ocupação do solo é estendida a 51 classes possíveis, sistematicamente discriminadas apenas à escala continental.

O módulo de classificação da cadeia de processamento do Globcover consiste em transformar os mosaicos de imagens multiespectrais MERIS, produzidos pelos módulos de pré-processamento, num mapa global de ocupação do solo. A tipologia foi definida usando o UN-LCCS com o objetivo de ser tanto quanto possível compatível com o GLC2000 (Fritz *et al.*, 2003). O módulo de classificação foi projetado pela *Université Catholique de Louvain (UCL)-Geomatics* para combinar a riqueza espectral e temporal dos dados MERIS e ser ao mesmo tempo globalmente consistente e ajustada a nível regional.

No LCCS, as classes de ocupação do solo são definidas por um conjunto de classificadores. O LCCS foi concebido como uma classificação hierárquica, que permite ajustar o detalhe temático da legenda à quantidade de informação disponível para descrever cada classe de ocupação do solo, enquanto segue uma abordagem de classificação normalizada. A ocupação do solo decorrente do Globcover foi concebida para ser um mapa global e coerente. Portanto, a sua legenda global é determinada pelo nível de informação que está disponível e que faz sentido à escala mundial. A legenda de nível 1, também chamada de "legenda global", cumpre esta exigência.

Em 2010, a segunda edição do GlobCover foi executada pela ESA e a UCL para produzir mosaicos MERIS bimestrais e anuais para o ano de 2009 e para derivar um novo mapa global de ocupação do solo. O objetivo era entregar o conjunto de produtos GlobCover 2009 durante o ano de 2010, demonstrando assim a importância do serviço operacional fornecido pela cadeia de processamento GlobCover.

3.2. Inventário *CORINE Land Cover*

Na Europa, os países membros da União Europeia têm uma produção cartográfica normalizada de dados de ocupação do solo de acordo com as

especificações do projeto CLC. Este projeto foi criado pelo JRC e pela EEA, para facultar dados de ocupação do solo a todos os estados membros. O projeto *CORINE Land Cover* iniciou-se durante a década de 1980 e consistiu na elaboração de uma carta temática de ocupação do solo para toda a Europa (CLC90), com base em interpretação visual de imagens de satélite – Landsat (*Multispectral Scanner* [MSS] e *Thematic Mapper* [TM]), referentes em Portugal ao período compreendido entre 1985 e 1987 – e em informação auxiliar, tendo sido Portugal o primeiro país a completar e a disponibilizar a referida carta.

A metodologia subjacente à produção da carta de ocupação do solo do CLC, produzida à escala 1:100 000, consiste na interpretação visual de imagens do satélite com apoio de informação auxiliar, com opção de uma área mínima de 25ha (EEA, 2002). A distância mínima entre linhas é de 100m, o que significa que nenhuma área é cartografada se as linhas que definem a sua fronteira distarem menos de 100m entre si. A informação encontra-se em formato vetorial e foi utilizado um sistema de nomenclatura hierárquico, organizado em três níveis e composto por 44 classes (no nível 3), que pretende abranger a totalidade das unidades de paisagem existentes nos diferentes estados membros (Bossard *et al.*, 2000). Ou seja, existiu uma tentativa de compatibilização entre as diferentes realidades da Europa, embora seja, por vezes, necessário incluir adaptações relativas à especificidade de cada contexto geográfico.

Na construção da legenda hierárquica, em três níveis:

- ◆ Nível 1 – 5 classes;
- ◆ Nível 2 – 15 classes;
- ◆ Nível 3 – 44 classes.

No nível 1 encontra-se o máximo de agregação da nomenclatura, sendo este nível dividido em quatro grandes temas:

- ◆ Territórios artificializados;
- ◆ Áreas com ocupação agrícola;
- ◆ Florestas e meios seminaturais;
- ◆ Meios aquáticos.

No nível 2, ainda se encontra na noção de ocupação do solo (com a exceção da classe habitação), de forte generalização semântica e gráfica dos objetos que as

compõem. O nível 3 de desagregação desta classe - 'Habitação' dá origem às classes 'Tecido Urbano Contínuo' e 'Tecido Urbano Descontínuo'. Contudo, no que diz respeito ao espaço urbano, estas não refletem o uso do solo, fazendo sim uma representação dos padrões espaciais da classe 'Tecido Urbano'. Por exemplo, a classe do urbano contínuo tem como critério que 80% no mínimo do total da área seja impermeabilizado, quanto à classe do urbano descontínuo, que essa percentagem se situe entre os 30 e os 80% (European Commission,1994).

Em 2000, a Agência Europeia do Ambiente EEA em colaboração com o JRC lançou os projetos *Image & CORINE Land Cover 2000 (I&CLC2000)* cujo principal objetivo foi o de atualizar a informação do primeiro *CORINE Land Cover* com imagens de satélite do ano 2000 do sensor *Enhanced Thematic Mapper Plus (ETM+)* do satélite Landsat-7. A produção do CLC2000 seguiu uma metodologia normalizada definida pela EEA e JRC baseada em análise visual assistida por computador. Esta metodologia consiste na identificação e delimitação de alterações a partir da comparação visual, entre as imagens utilizadas para a produção do CLC1990 e as imagens a utilizar para a produção do CLC2000, assim como em informação auxiliar. O processo viria a ser repetido em 2006 e seriam aferidas igualmente as transformações verificadas entre 2000 e 2006.

Assim, a equipa nacional do CLC2000 em Portugal, teve a responsabilidade de gerir os seguintes produtos:

- ◆ P-CLC1990 melhorado – cartografia nacional de ocupação de solo de 1985/86/87 corrigida;
- ◆ P-CLC2000 – cartografia nacional de ocupação do solo à escala baseada em imagens de satélite Landsat do ano 2000;
- ◆ P-CLC2006 – cartografia de caracterização do uso e ocupação do solo em 2006 para Portugal Continental.

3.3. Inventário Florestal Nacional

O Inventário Florestal Nacional de 1995 (IFN4) foi um serviço de informação da responsabilidade da Direção Geral das Florestas (DGF), atual Instituto de Conservação da Natureza e Florestas (ICNF), que teve como principal objetivo avaliar e monitorizar a extensão e condição dos recursos florestais em Portugal Continental. Esta informação é de cariz oficial e é utilizada para o estabelecimento de políticas, planos e projetos que visam o desenvolvimento sustentável da floresta nacional (Direção Geral dos Recursos Florestais [DGRF], 2005). O IFN fornece informação estatística sobre os seguintes temas:

- ◆ Áreas de ocupação do solo de Portugal Continental;
- ◆ Estrutura dos povoamentos florestais;
- ◆ Produção florestal de bens lenhosos e não lenhosos;
- ◆ Vitalidade e sanidade dos povoamentos florestais.

Como resultado da realização do IFN de 1995 foram gerados vários produtos, nomeadamente mapas de uso e ocupação do solo em formato matricial à escala 1:1 000 000, uma aplicação informática designada AreaStat, para consultas sobre as áreas das classes de uso e de ocupação do solo em Portugal Continental, e um ficheiro de pontos em formato digital, que contém as coordenadas aproximadas dos fotopontos (pontos marcados sobre fotografias aéreas) utilizados como base para a execução das análises estatísticas de uso/ocupação do solo por unidade territorial.

A classificação foi realizada por fotointerpretação dos referidos pontos sobre fotografias aéreas em formato analógico e à escala 1:10 000, referentes ao ano de 1995, e por levantamentos de campo. Cada fotografia aérea representa uma área real no terreno de cerca de 2500ha e os fotopontos estão afastados entre si cerca de 700m no eixo das abcissas e 1000m no eixo das ordenadas. Cada fotoponto foi classificado em função das características foto-interpretadas na mancha de terreno onde o ponto incidiu de acordo com a definição de classes estabelecida na nomenclatura de uso e/ou ocupação do solo do IFN. Entendeu-se por mancha a porção de terreno de área igual ou superior a 0,5ha e de largura média igual ou superior a 20m, que constitui uma unidade homogénea do ponto de vista do uso e ocupação do solo.

O sistema de classificação do IFN é não-hierárquico e a *posteriori*, tendo sido estruturado com o objetivo principal de caracterizar com detalhe a classe de uso florestal. Cada uma das classes foi definida com rigor para garantir que todo o território nacional fosse alocado a uma determinada classe, de forma clara e inequívoca. As definições da nomenclatura regulam a atribuição a cada fotoponto de um código por cada um dos 13 campos que compõem o sistema. A combinação destes códigos determina o uso e/ou a ocupação do solo daquele fotoponto. Houve o cuidado de harmonizar e normalizar as definições utilizadas com os requisitos do estudo internacional *Temperate and Boreal Forest Resources assesment* (TBFRA) (2000), cujo início coincidiu com a fase de definição da nomenclatura do IFN de 1995 (DGRF, 2005).

A cada fotoponto está, por conseguinte, associada informação relativa a um conjunto de atributos que cobrem quatro áreas temáticas: *i)* Uso do Solo; *ii)* Estrutura dos Povoamentos; e *iii)* Produção Florestal e Condição dos Povoamentos. Estas áreas temáticas dividem-se nos seguintes atributos:

- ◆ Uso do Solo (6 atributos);
- ◆ Ocupação Florestal (6 atributos);
- ◆ Grupos Florestais (4 atributos);
- ◆ Ocupação Primária (15 atributos);
- ◆ Ocupação Secundária (15 atributos);
- ◆ Grau de Coberto (7 atributos).

É importante referir que o posicionamento de cada ponto do IFN4 tem um erro associado não constante, pelo que a sua utilização para análises que exijam uma georreferenciação precisa deve ser revestida de alguns cuidados. Todos os dados utilizados eram originais e foram recolhidos especificamente para a realização do IFN.

O IFN5 foi baseado numa cobertura aerofotográfica digital realizada durante os anos de 2004 a 2006 e em levantamentos de campo efetuados entre dezembro de 2005 e junho de 2006. A aplicação para consulta dos resultados do 5.º Inventário Florestal Nacional, o FloreStat, foi desenvolvida para permitir a consulta de todas os indicadores produzidos no IFN5, agregados em quatro temas: *i)* áreas de uso/ocupação do solo; *ii)* estrutura; *iii)* produção; e *iv)* e condição dos povoamentos. Estas consultas podem ser realizadas, dependendo do indicador, para as unidades territoriais Portugal,

Portugal continental, Nomenclatura das Unidades Territoriais (NUTS) II e III, regiões do Plano Regional de Ordenamento Florestal (PROF) e concelhos. Contudo, ao contrário do IFN4, a informação cartográfica não se encontra disponível ao público.

O IFN6 teve por base um processo multitemporal de análise de alteração do uso/ocupação do solo (para os anos de referência de 1995, 2005 e 2010), incluindo, também, uma caracterização detalhada ao nível das classes de ocupação agrícola. Os resultados preliminares foram apresentados em 11 de fevereiro de 2013, na Tapada Nacional de Mafra, prevendo-se para 2014, a edição do Relatório Final do IFN 6.

Para além destes aspetos, ao nível da nomenclatura, foram introduzidos ajustamentos nas definições de algumas classes (por ex.: matos e pastagens), de modo a aumentar o grau de compatibilização das estatísticas produzidas com outros processos de produção de informação sobre recursos florestais e agrícolas de âmbito nacional. O primeiro nível de informação deste IFN (uso do solo) considera seis grandes classes:

- ◆ Floresta;
- ◆ Agricultura;
- ◆ Matos e pastagens;
- ◆ Águas interiores e zonas húmidas;
- ◆ Urbano;
- ◆ Improdutivos.

A nomenclatura de uso/ocupação do solo utilizada no IFN6 encontra-se estruturada em nove níveis de informação, organizados em três grandes temas: uso do solo; ocupação do solo; e análise da paisagem. A nomenclatura é detalhada em maior pormenor para os usos relacionados com o coberto agroflorestal, designadamente os usos florestais e agrícolas.

3.4. Carta de Ocupação do Solo de Portugal

A Carta de Ocupação do Solo de Portugal de 1990, realizada à escala 1:25 000, tem como metodologia de base a interpretação de fotografia aérea vertical à escala 1:15 000 de 1990 e 1991; a Unidade Mínima Cartográfica é de 1ha. A legenda é

semelhante à do Inventário *CORINE Land Cover*, pelo que também é hierárquica. A COS de 1990 (COS90) foi produzida pelo Centro Nacional de Informação Geográfica (CNIG), posteriormente integrado no Instituto Geográfico Português (IGP) e atualmente sendo parte da Direção Geral do Território (DGT) – em conjunto com a Associação das Empresas Produtoras de Pasta de Celulose (ACEL) – atual Associação Nacional da Indústria Papeleira (CELPA) – através da interpretação visual, seguida de digitalização em ecrã, de fotografia aérea em filme de infravermelho colorido obtida no verão de 1990. Este projeto consistiu na obtenção de informação gráfica e numérica sobre a ocupação do solo no território de Portugal.

Numa primeira fase foram delimitadas sobre as fotografias aéreas, as parcelas distintas quanto à sua ocupação, utilização ou objetivos de produção. Entende-se por parcela, a porção de terreno igual ou superior à UMC e de largura média igual ou superior a 40m, que constitua uma unidade homogénea do ponto de vista da utilização e ocupação do solo (Instituto Florestal, 1994). Em seguida, cada parcela foi identificada de acordo com o sistema de classificação desenvolvido para o efeito, que é não-hierárquico e de aplicação *a posteriori*. No sistema de classificação da COS90 a nomenclatura determina as regras de utilização de três dígitos que compõem os códigos a atribuir aos polígonos.

Propõe-se então uma codificação por três dígitos, em que os dois primeiros sejam obrigatoriamente alfanuméricos e o terceiro numérico ou não. O primeiro dígito contém informação sobre a utilização do solo. Um segundo dígito é relativo à ocupação, e um terceiro dígito pretende pormenorizar alguns aspetos da utilização do solo, podendo indicar tanto o grau de coberto, no caso das espécies florestais, como o tipo específico de cobertura, em especial nas áreas agrícolas. A legenda estabelece assim, uma grande variedade de combinações entre os vários tipos de ocupação, totalizando mais de setecentos tipos de diferentes ocorrências.

Pela semelhança existente entre a legenda COS e a legenda CORINE, mantêm-se os problemas referidos anteriormente. A classe do 'Espaço Urbano' (nível II), dividida em 'Tecido Urbano Contínuo' (nível III) e 'Tecido Urbano Descontínuo' (nível III), continua, no nosso entender, a não responder às necessidades do planeamento

local/regional de áreas sobretudo urbanas, na medida em que, por exemplo, não se percebe o que significa o conceito de urbano utilizado.

O todo aqui considerado como objeto 'Tecido Urbano Descontínuo' não oferece um código suficientemente claro para os diferentes recetores, por forma a permitir a construção de um significado comum. As partes que constituem este objeto não ficam explícitas na noção do todo, levando a uma quebra de comunicação. Em relação ao exemplo dado, não é de se supor a existência de áreas de pequena indústria, no tecido urbano, seja ele contínuo ou descontínuo? A interpretação hierárquica da legenda fica assim, segundo é dado a perceber, sem uma corrente contínua de transmissão de informação.

Esta carta é constituída por 638 folhas correspondentes à segmentação da série cartográfica 1:25 000 do Exército em formato vetorial, dividindo o espaço em polígonos de ocupação e uso do solo, não estando contemplados elementos lineares ou pontuais. Deficiências nas fotografias aéreas utilizadas impediram a obtenção de informação em diversas áreas do continente pelo que, a COS90 não cobre a totalidade do território nacional faltando 50 folhas, o que perfaz 8% da área total do país.

O projeto Carta de Uso e Ocupação do Solo de Portugal Continental para 2007 (COS2007) pretende atualizar a sua edição anterior (COS90) mas introduz uma série de alterações significativas, quer a nível das metodologias e regras de produção cartográfica, quer a nível da nomenclatura utilizada (Caetano *et al.*, 2008).

Importa desde já referir que a UMC da COS2007 é igual à da edição de 1990, mas enquanto a distância mínima entre linhas na COS90 era de 40m, na COS2007 é de 20m. No que diz respeito ao método de produção, a COS2007, tal como a COS90 também se baseia em interpretação visual de imagens aéreas. No entanto, as imagens aéreas utilizadas para a produção da COS2007, ao contrário das utilizadas para a produção da COS90, foram ortorretificadas, o que garante uma maior exatidão posicional da própria cartografia. O facto de as imagens aéreas de 2007 terem sido adquiridas por uma câmara digital, ao contrário das de 1990 que foram adquiridas por uma máquina fotográfica tradicional, garante uma maior qualidade radiométrica das imagens, permitindo assim uma identificação do uso e ocupação do solo mais correta. Por outro lado, na produção da COS2007, ao contrário do que aconteceu com a COS90,

utilizaram-se séries multitemporais intra-anuais de imagens de satélite, que permitem uma melhor caracterização da fenologia da vegetação, e conseqüentemente uma identificação mais correta de algumas classes de uso e ocupação do solo.

Outra das importantes novidades da COS2007 é o facto de apresentar uma nomenclatura de uso e ocupação do solo compatível com a nomenclatura da carta CLC, que constitui um produto de referência em uso e ocupação do solo, na Europa e em Portugal. A nomenclatura da COS2007 é hierárquica com cinco níveis e tem 193 classes de uso e ocupação do solo ao nível mais detalhado. Decidiu-se que as classes dos primeiros três níveis da nomenclatura da COS2007 seriam semelhantes às classes da nomenclatura CLC. Refira-se que a nomenclatura CLC tem apenas três níveis hierárquicos que representam a variedade da paisagem em 44 classes (Bossard *et al.*, 2000). Esta opção de se manter as classes do CLC até ao 3º nível, permite a integração da cartografia produzida a nível nacional com a produzida a nível internacional. Na definição da nomenclatura da COS2007 foi também feito um esforço de harmonização, em termos de definições de classes, com outras nomenclaturas de relevo internacional, como é o caso do *Temperate and Boreal Forest Resources Assessment 2000* (TBFRA, 2000; UN-ECE/FAO, 2000), e do *Land Cover Classification System* (Di Gregorio e Jansen, 2000) das Nações Unidas.

O esforço de harmonização com nomenclaturas internacionais que constituem normas, nomeadamente no que respeita à diretiva europeia *Infrastructure for Spatial Information in the European Community* (INSPIRE), garante que a COS2007 esteja em consonância com essas normas, e como tal respeitando o moderno conceito de dados geográficos normalizados preconizado pela referida diretiva. Ainda no que respeita à importância da adoção de normas internacionais e conseqüente normalização da informação, chama-se a atenção para o facto de a COS2007 ter sido produzida no sistema de referência *European Terrestrial Reference System 1989* (ETRS89), no sentido de possibilitar uma compatibilização mais fácil e exata da informação produzida a nível nacional com outra produzida a nível europeu.

3.5. Comparação das nomenclaturas

Normalmente, ao discutir-se a escala - espacial - dos mapas de uso e ocupação do solo utilizam-se termos como extensão e resolução. A resolução é entendida como a UMC, *e.g.* o menor polígono representado ou a célula (píxel) de uma grelha afeta à estrutura matricial. Nesta estrutura, as células da grelha são normalmente quadradas (pelo menos nos sistemas comerciais), organizadas numa grelha retilínea e uniforme em toda a área modelada, ao passo que na estrutura vetorial coexistem polígonos de variadas dimensões, podendo o mais pequeno deles ser considerado como a resolução do modelo.

A extensão descreve a área geográfica total sobre a qual o modelo é aplicado. Quanto à escala, este termo encontra-se muitas vezes envolto em confusão porque apresenta diferentes significados para várias disciplinas. Os geógrafos definem, normalmente, escala como o rácio entre o comprimento de uma unidade de distância (escala gráfica) num mapa e o comprimento da mesma unidade de distância medida no terreno (realidade) (Greenhood, 1964). Um mapa de grande escala (*e.g.* um mapa de um quarteirão urbano à escala 1:2000) normalmente denota grande pormenor, mas cobre uma área relativamente pequena. Os mapas de pequena escala apresentam um pormenor diminuto, mas cobrem uma área muito mais abrangente, como o mapa da Europa à escala 1:10 000 000.

Outros cientistas, do core das ciências sociais e humanas, atribuem significados opostos aos termos grande e pequena escala. Para estes, uma aplicação de larga escala significa que cobre uma grande extensão e um de pequena extensão corresponde a um estudo detalhado cobrindo uma área diminuta. Pegando nesta definição, a denotação “escala” pode ser completamente afastada sem que isso tenha implicações no significado da frase. Além disso, o termo escala tem sofrido interpretações discrepantes à medida que têm ocorrido alterações na ciência geográfica, nomeadamente à medida que se avançou dos dados analógicos (mapas) para os produtos digitais (níveis de informação – *layers* – inseridos num SIG).

Para obviar a possíveis confusões, pode-se enveredar por uma designação lata, inserindo dois termos, escala fina e grosseira, que possuem uma significância mais

intuitiva. A resolução e a extensão podem servir para identificar/descrever as análises numa escala fina ou grosseira. Os modelos de escala fina conglobam exíguas áreas de análise (pequena extensão) e pequenas dimensões de células (*i.e.*, grandes resoluções espaciais) e, portanto, são de grande escala na perspectiva geográfica do termo. Por antítese, os modelos de escala grosseira apresentam grandes superfícies espaciais de análise e células de maior dimensão, correspondendo ao que se entende por pequena escala geográfica. A Figura 3.1 fornece um exemplo da transição gradual entre uma pequena escala (A) e uma grande escala (E).

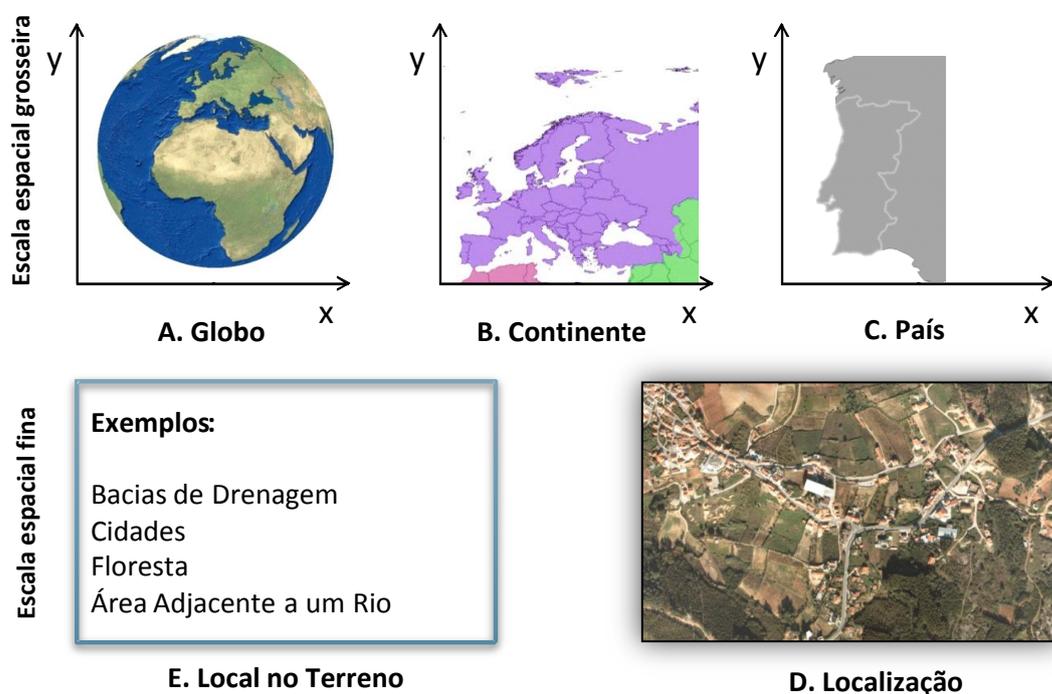


Figura 3.1 - Escalas espaciais hierárquicas

A resolução e a extensão são muitas vezes empregues para descrever tanto as escalas temporais como as espaciais. No entanto, importa tornar essas distinções mais explícitas para que não surjam dúvidas sobre a que escala é que se refere determinado contexto, o que se reveste de uma importância fundamental quando se entra no domínio da cartografia de uso e ocupação do solo.

No contexto desta dissertação aborda-se essencialmente a questão da complexidade espacial. Esta última representa a extensão segundo a qual um modelo é

especialmente explícito. Analisando a relação entre a área cartografada e a UMC no conjunto dos quatro sistemas de classificação de uso e ocupação do solo anteriormente analisados pode aferir-se que o único sistema que não segue a regra de um aumento da resolução, *i.e.*, diminuição da UMC com a diminuição da área cartografada – ambos relacionados com a escala de produção cartográfica – é o IFN, que apresenta uma resolução demasiado grosseira.

Uma forma bastante imediata de se compararem sistemas de classificação consiste no confronto direto entre as características das nomenclaturas dos produtos em questão. De acordo com os outros parâmetros dos sistemas de classificação, descritos no presente capítulo, os sistemas de classificação nacionais e internacionais analisados foram agrupados em três conjuntos (Figura 3.2). Existe um sistema de classificação não-hierárquico *a priori*, o da Carta de Uso do Solo da Área Metropolitana de Lisboa (CARTUS/AML) (Tenedório *et al.*, 1999), mas por não englobar a totalidade do território nacional não foi analisado no contexto desta dissertação.

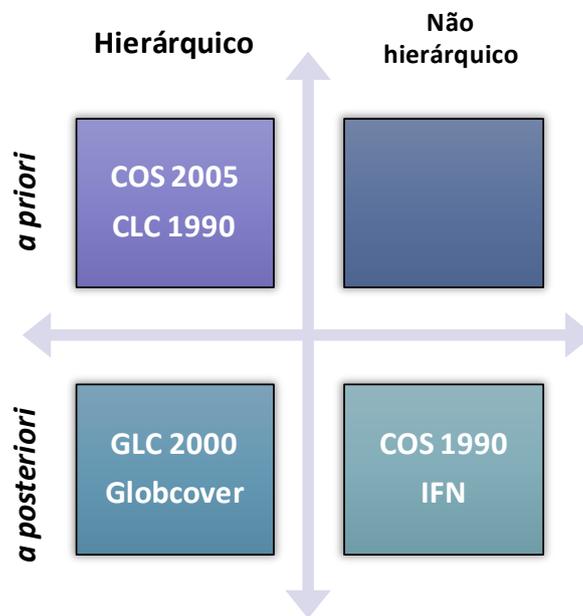


Figura 3.2 - Sistemas de classificação de acordo com as suas características

Capítulo 4 - Detecção Remota

Os princípios básicos da detecção remota já foram discutidos e explicados na literatura especializada em numerosas ocasiões. Nesta dissertação será dada uma breve e concisa introdução, mas não uma explicação abrangente dos fundamentos. Em vez disso, será feita referência a literatura de referência, como Campbell (1996), Jensen (2004), Mather (2004) ou Schowengerdt (1997).

4.1. Formação da imagem

Os dados provenientes de uma imagem de detecção remota são representados como matrizes compostas por $i=1, \dots, I$ linhas e $j=1, \dots, J$ colunas. Um píxel na posição (i, j) pode ser definido, de acordo com os seus valores de reflectância em todas as N bandas da imagem de satélite, como um vetor de píxel:

$$\mathbf{x}_{ij} = \begin{bmatrix} NR_{ij1} \\ NR_{ij2} \\ NR_{ij3} \\ NR_{ij4} \\ \vdots \\ NR_{ijk} \end{bmatrix}. \quad (4.1)$$

Este vetor \mathbf{x}_{ij} representa os níveis radiométricos (NR), *i.e.* os valores de cinza (0, 1, ..., 255 para dados de 8 bits ou 0, 1, ..., 65536 para dados de 16 bits) dos píxeis nas bandas individuais (k). Portanto, o valor de zero equivale ao preto (*i.e.*, sem reflexão, logo com absorção máxima) e 255 ou 65536 ao branco (reflexão máxima significando que não há absorção).

4.1. Resolução radiométrica, espectral e espacial

A resolução espectral dos sistemas de detecção remota é entendida como os intervalos de comprimento de onda que o sensor do satélite utilizado pode detectar. Os sistemas de detecção remota existentes têm diferentes resoluções espectrais e, portanto, também fornecem dados/imagens diferentes. Para uma descrição detalhada dos fundamentos físicos da radiação pode-se consultar Schott (1997).

A resolução radiométrica de um satélite é uma medida da menor radiação eletromagnética discernível. Dependendo do detector usado, pode variar entre 6 *bits* (64 valores de cinzento) e 16 *bits* (65536 valores de cinzento) para sistemas modernos como Landsat 8.

Além de resolução espectral, os sistemas de satélite também se diferenciam pela sua resolução espacial. A forma de medir esta resolução mais frequentemente usada no âmbito da detecção remota é o campo de visão instantâneo (*Instantaneous field of view* [IFOV]). O IFOV (Figura 4.1) é definido como a área observada diretamente por um sensor.

Um detector de um satélite é constituído por vários sensores. Cada um desses sensores capta uma determinada área representada por um píxel. O total da imagem é composto por esses píxeis. A resolução espacial de uma imagem depende da área real mapeada por um píxel. Quanto maior ou melhor a resolução espacial de um detector, menores são os objetos que podem ser identificados nas imagens de satélite (Figura 4.1). Nesta dissertação são usadas imagens de satélite de média/alta resolução espacial e alta resolução espectral.

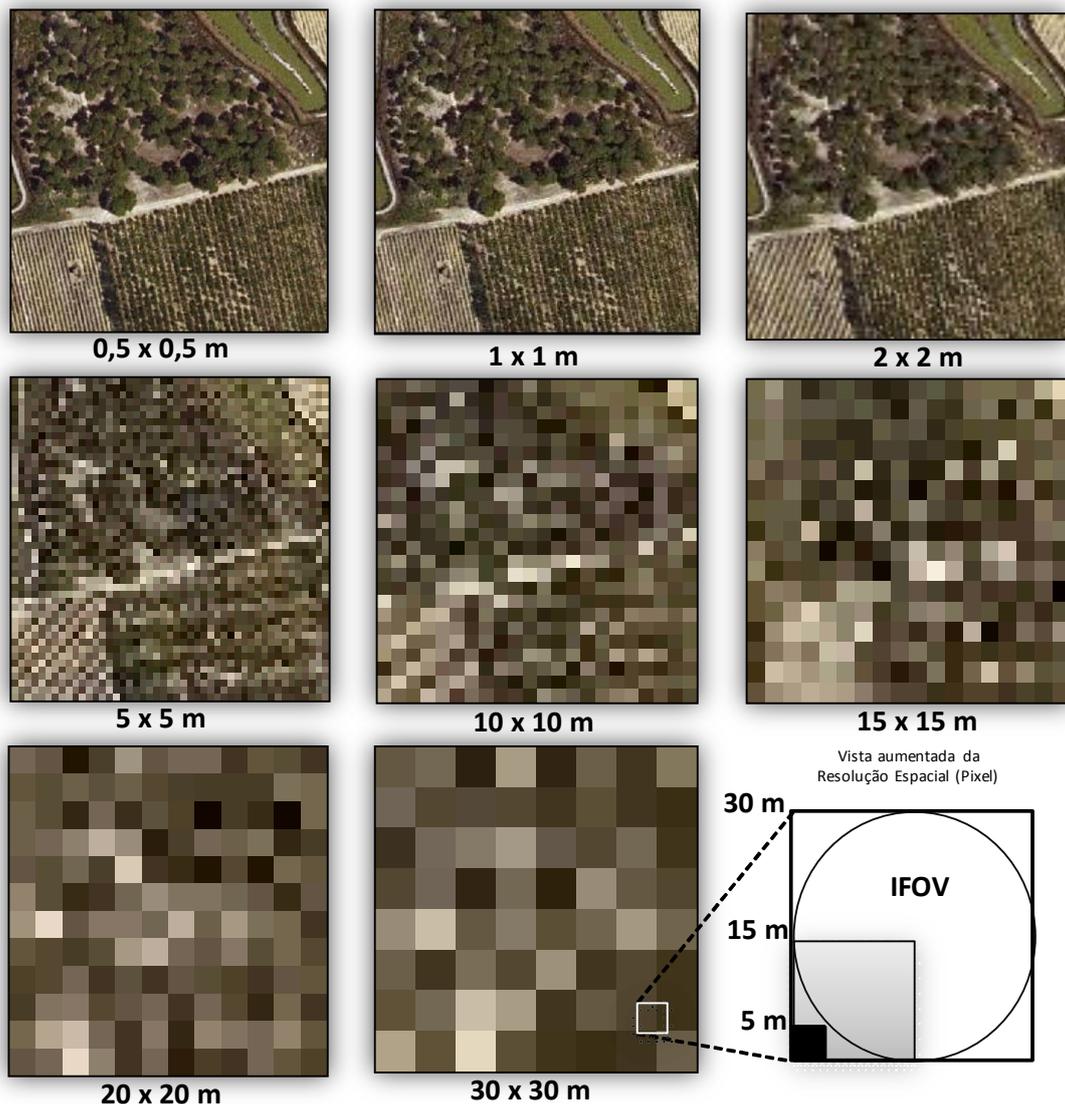


Figura 4.1 - Diferentes resoluções espaciais

4.2. Assinaturas espectrais

Um pressuposto básico em detecção remota é que superfícies específicas, tais como rocha, água ou vegetação têm um comportamento característico de reflexão ou de emissão e, portanto, podem ser distinguidas pela sua assinatura espectral específica. Essa assinatura é influenciada por vários fatores, tais como as propriedades do material (da superfície ou interno), a topografia ou a modificação de radiação pela atmosfera (Richards e Jia, 1999). A Figura 4.2 mostra a assinaturas espectrais típicas de superfícies selecionadas. Note-se que a assinatura muda dependendo das condições da superfície

consideradas. A reflectância da água, por exemplo, depende se o corpo de água é profundo ou superficial, translúcido ou turvo, calmo ou agitado.

Com o auxílio destas refletâncias típicas, a ocupação da superfície observada pelos sensores do satélite pode ser determinada com maior detalhe. Como regra, a superfície ou é determinada manualmente ou por computador, fazendo uso de um esquema de classificação, *i.e.*, os dados de satélite são divididos num número finito de classes de idêntica importância em termos de conteúdo.

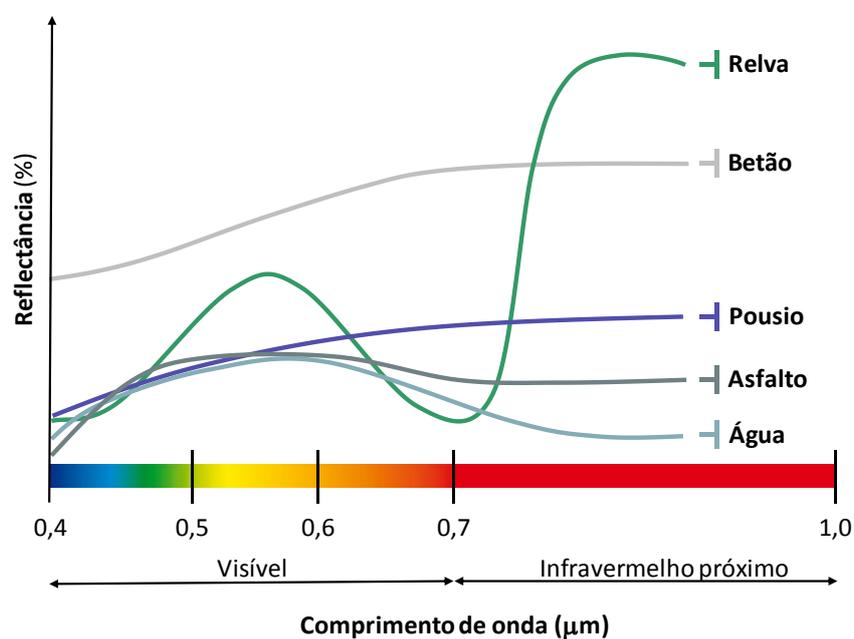


Figura 4.2 - Assinaturas espectrais de diferentes superfícies (adaptado de Richards e Jia, 1999)

Para a classificação de dados de satélite existem duas abordagens principais que por serem conceptualmente anacrônicas devem ser distinguidas: o método baseado em píxeis individuais (píxel-a-píxel) e o método baseado em objetos. No caso do método baseado em píxeis, cada píxel individual da imagem é analisado e classificado de acordo com suas características espectrais. Os métodos baseados em objetos assentam no pressuposto de é muito provável um píxel pertencer à mesma classe do seu – píxel - vizinho. Numa primeira etapa, o espaço da imagem é segmentado em objetos homogêneos, constituídos por píxeis semelhantes. Esses objetos são então agrupados em classes com o mesmo significado semântico. No entanto, para a classificação, para

além das características espectrais, são utilizadas características adicionais tais como a forma, as relações de vizinhança, a textura e a dimensão dos objetos.

4.3. Processamento de imagem píxel-a-píxel

A grande maioria dos métodos de classificação baseados no píxel podem ser subsumidos sob a análise do termo *cluster*. Neste caso, são analisados os vetores individuais N-dimensionais do píxel num espaço característico (*feature*) N-dimensional e atribuídos a uma classe, por exemplo, com o auxílio de métodos estatísticos (*e.g.* mínima distância e máxima verosimilhança), com técnicas de lógica difusa (*fuzzy*) ou com redes neuronais artificiais. O recurso a ser classificado é geralmente a assinatura espectral de um píxel. O objetivo de todos estes métodos é a separação externa de classes internamente homogêneas, *i.e.*, todos os valores (espectrais) alocados a uma classe devem ser o mais semelhantes possível, ou dito de forma inversa, as diferenças dos valores das várias classes (espectrais) devem ser tão grandes quanto possível. Esta classificação pode ser realizada sem supervisão ou supervisionada, neste último caso com o auxílio de dados de referência e áreas de treino.

Os métodos de classificação baseados no píxel têm constituído o tipo de abordagem mais utilizado na classificação de imagens de satélite. Devido a este fato, os referidos métodos são descritos em detalhe e matematicamente derivados quase até à exaustão na literatura especializada. O foco desta dissertação é sobre os métodos baseados em objetos, de modo que para uma explicação rigorosa dos métodos baseados em píxeis individuais seja feita referência a literatura científica como Lillesand *et al.* (2003) e Richards e Jia (1999).

Nos últimos anos, apesar de alguns desenvolvimentos recentes, os métodos puramente baseados em píxeis têm vindo cada vez mais a atingir os seus limites. Uma das razões é o fato de que com o aumento da resolução espacial das imagens de satélite, com muita frequência a (pequena) base de recurso de valores espectrais apenas fornece resultados diminutos, insuficientes para a classificação. Além disso, há uma quantidade crescente de dados adicionais, como modelos digitais de elevação (*Digital Elevation Models* [DEM]) ou outros também provenientes de SIG que podem ser

usados na classificação (Rocha *et al.*, 2001; Tenedório *et al.*, 2006). Parece pertinente para futuras investigações integrar esses dados adicionais em análise de imagens de satélite. A análise de imagens de satélite com base em objetos tem aqui um grande potencial, uma vez que tem uma base de recursos muito grande para a classificação e dados e os dados adicionais provenientes de outras fontes podem ser facilmente integrados e utilizados para análise.

Blaschke e Strobl (2001) levantaram uma questão provocante: “o que há de errado com os píxeis?” Tendo identificado uma insatisfação crescente com a análise de imagens baseada no píxel. Apesar desta crítica não ser recente (Cracknell, 1998; Blaschke e Strobl, 2001; Burnett e Blaschke, 2003; Blaschke *et al.*, 2004) os autores observaram algum deslumbramento acerca das aplicações para “além dos píxeis”.

4.4. Processamento de imagem baseada em objeto

A análise de imagem baseada em objetos controlada por computador pode ser comparada, numa primeira aproximação, com a percepção visual. Assim, em interpretação de imagem visual o intérprete reconhece conscientemente formas específicas e correlações que ultrapassam os valores de cinza puros e as tonalidades de cor da imagem. Isto é, percebe padrões típicos e associa-los a objetos reais. Para além da informação puramente relacionada com a cor, estes padrões resultam de outras características como a textura, a forma, o tamanho ou das relações entre objetos individuais. Em geral, a análise de imagens baseada em objetos também visa um procedimento semelhante à interpretação visual e muito particularmente o *software* de processamento de imagem denominado eCognition®. Apesar da complexidade e do desempenho da percepção humana nunca chegarem a ser atingidos, pode-se afirmar que existem certos paralelismos.

Os métodos de análise de imagem baseada em objeto, assentes em bases de conhecimento, pontificam entre as chamadas técnicas de visão computacional (Wilkinson, 1999). Até agora, estes métodos têm desempenhado um papel pouco relevante em deteção remota. Devido às crescentes exigências de que a deteção remota tem sido alvo e às suas possibilidades crescentes, o funcionamento dos

métodos usuais de classificação pixel-a-pixel teve de ser reavaliado e redesenhado. Face ao grande potencial da análise de imagens baseada em objetos, os trabalhos recentes de desenvolvimento de *software* e investigação vão cada vez mais nesse sentido, como é disso exemplo o software eCognition® da *Definiens Imaging*, utilizado nesta dissertação.

Nesta abordagem (baseada em objetos), a imagem a ser analisada é segmentada em objetos individuais. Os segmentos formados devem refletir os objetos presentes na realidade. Podem ser usados vários métodos para efetuar a segmentação. Os objetos podem ser classificados por métodos heurísticos ou por técnicas baseadas em conhecimento, tais como redes semânticas. No segundo caso - sistemas baseados em conhecimento - a base de regras para a classificação é estabelecida através de uma combinação de características (*features*). Para além da assinatura espectral, características como a forma, as relações de vizinhança, a textura e o tamanho dos objetos, podem ser utilizadas para descrever o objeto. Por fim, recorre-se a uma função de classificação para alocar os objetos a um determinado número de classes, de acordo com a descrição das suas características.

Um denominador comum destas aplicações foi e ainda é, o facto de serem baseadas na segmentação de imagens (*cf.* Lang, 2008; Hay e Castilla, 2008; Blaschke *et al.*, 2008). A segmentação de imagens não é um método novo (Haralick, 1983; Haralick e Shapiro, 1985; Pal e Pal, 1993), mas tem as suas raízes no processamento de imagens a nível industrial e não foi usada de forma extensiva em aplicações geo-espaciais durante toda a década de 1980 e 1990 (Blaschke *et al.*, 2004).

Dentro de aplicações de deteção remota, existem numerosos algoritmos e o seu número tem aumentado substancialmente nos últimos anos (Baatz e Schäpe, 2000; Blaschke *et al.*, 2004; Neubert *et al.*, 2008). Da perspetiva de um algoritmo, a segmentação de uma imagem, geralmente encontra-se dividida em quatro categorias: (i) a baseada em pontos; (ii) a baseada em margens; (iii) a baseada em regiões; e (iv) as combinatórias (Schiewe, 2002). Informação mais detalhada sobre estas técnicas de segmentação pode ser encontrada em Pal e Pal (1993). No entanto, independentemente de qual dos métodos é aplicado, a segmentação retribui os blocos decorrentes da análise de imagem baseada em objetos (Hay e Castilla, 2008; Lang,

2008). Isto pelo menos por agora, pois futuramente o utilizador poderá, finalmente, poder lidar com objetos espacialmente difusos (Gorte, 1998) ou geo-campos (Cova e Goodchild, 2002).

Podem-se entender os segmentos como regiões que são geradas por um (ou mais) critério(s) de homogeneidade numa ou mais dimensões (num espaço característico). Assim, os segmentos possuem informações espectrais adicionais relativamente aos píxeis isolados (*e.g.* valores por banda e também valores de mínimos e máximos, rácios, variância etc.). No entanto, uma vantagem ainda maior do que a diversificação das descrições de valor espectral dos objetos é a obtenção de informação espacial adicional que estes viabilizam (van der Werff e van der Meer, 2008; Hay e Castilla, 2008).

Os métodos de análise de imagem baseada em objeto, assentes em bases de conhecimento, integram o conhecimento sobre os objetos na análise. Aqui é feita uma diferenciação entre o conhecimento declarado (conhecimento proveniente de vários conjuntos de dados), conhecimento processual (método utilizado para manusear os conjuntos de dados) e o conhecimento *a priori* (conhecimento sem relação com os dados de inventário/amostra analisados). Voltar-se-á a falar com maior detalhe da classificação de imagem baseada em objeto na secção 5.3.

4.4.1. Segmentação – Requisitos, desempenho e reprodutibilidade

A metodologia baseada em objetos segmenta a imagem em objetos individuais que são homogéneos em si e formam a base para uma análise mais profunda da imagem. Esse processo – denominado de segmentação – já é usado há algum tempo no reconhecimento de padrões e monitorização de materiais e encontram-se disponíveis diversos algoritmos para o realizar (Blaschke, 2000).

Antes da OBIA, a principal tarefa de segmentação de imagens era produzir um conjunto de segmentos não-sobrepostos (polígonos), e esta etapa encontrava-se bastante desligada do processo de classificação. Porém, o principal problema, é a escala: a escala é uma “janela de perceção” (Marceau, 1999). Se a resolução espacial é maior que o tamanho dos objetos de interesse normalmente fica-se com várias escalas

de representação na imagem (*cf.* secção 3.5). Os algoritmos de segmentação são usados na expectativa de que vão dividir a imagem em (a) áreas relativamente homogêneas e (b) grupos de píxeis semanticamente significativos.

Burnett e Blaschke (2003) denominaram estes grupos de “objetos candidatos” os quais são reconhecidos no futuro processamento adicional e transformados em objetos significativos. É sabido que as regiões semanticamente significativas se encontram na imagem a diferentes escalas de análise (Hay *et al.*, 2001, 2003), e a OBIA está indissociavelmente ligada aos conceitos de análise multi-escala (Burnett e Blaschke, 2003; Benz *et al.*, 2004 e Lang, 2008), mesmo que se privilegiem níveis únicos direcionados para aplicações específicas (Lang e Langanke, 2006; Lang, 2008; Weinke *et al.*, 2008).

Burnett e Blaschke (2003) entendem o conceito de OBIA MSS/ORM. Lang e Langanke (2006) desenvolveram um OLR iterativo e Tiede *et al.* (2008) aplicaram o conceito OLR convincentemente para dados LiDAR. Weinke *et al.* (2008) aplicaram e avaliaram empiricamente ambos os conceitos de OBIA e encontraram prós e contras em cada abordagem.

Em imagens de muito alta resolução, *e.g.* ortofotomapas, a uma escala pequena pode-se discriminar campos ou florestas, enquanto em escalas maiores se podem discriminar plantas ou árvores individuais. Portanto, os parâmetros e limites dos algoritmos de segmentação OLR devem ser ajustados para a escala correta de análise. No entanto, muitas vezes não é possível determinar esta escala com antecedência porque os diferentes tipos de imagens exigem diferentes escalas de análise, e além disso, em muitos casos os objetos da mesma família aparecem na mesma imagem a diferentes escalas de análise (Arbiol *et al.*, 2006). Uma boa visão geral sobre esta temática é dada por Haralick e Shapiro (1992), Sagerer e Niemann (1997), bem como Sonka *et al.*, (1998). Uma descrição extensa de abordagens associadas a trabalhos práticos pode ser encontrada em Niemeyer (2001).

Simplificando, existem três critérios principais segundo os quais os diferentes algoritmos de segmentação combinam os píxeis de imagem individuais de maneira a formar objeto: *i)* a homogeneidade dentro de um segmento; *ii)* a separação de segmentos adjacentes; e *iii)* a homogeneidade de forma (simplicidade dos limites do

segmento versus os seus atributos fractais). Estes critérios não podem ser encontrados na sua totalidade de forma simultânea, dado que em parte se autoexcluem. Portanto, muitos métodos de segmentação, enfatizam particularmente determinados critérios. Uma explicação detalhada de todos os métodos está para além do âmbito da presente dissertação e remete-se o leitor para os estudos mencionados no início desta secção.

Por princípio, para os diferentes (3) métodos existem tanto algoritmos chamados de margem, como algoritmos baseados na região. Os métodos baseados na margem começam a segmentação com uma procura por gradientes fortes na imagem. Presume-se que estas discontinuidades constituem os limites do segmento. A seguir, as margens encontradas por este tipo de detetores são construídas para formar uma rede de limites. Em especial o critério da forma (simples) dos limites do segmento pode ser tomado aqui em consideração. Os algoritmos baseados na região, operam a partir de uma região inicial, e decidem de acordo com critérios pré-definidos se um determinado píxel é ou não alocado a essa região. Assim, pode-se considerar a existência de uma abordagem de cima-para-baixo (*top-down*), onde a imagem total é segmentada em objetos cada vez menores até que todos os segmentos satisfaçam os critérios pré-definidos, e uma abordagem de baixo-para-cima (*bottom-up*) baseada em píxeis denominados de sementes. Estas sementes são fundidas com píxeis vizinhos de forma a criar um segmento, até que certos critérios de truncamento sejam excedidos (*cf.* secção 5.4.1).

4.4.2. Requisitos para a segmentação

Os numerosos métodos de segmentação já desenvolvidos para outras áreas como a medicina, a neuro-informática ou as telecomunicações são muito especializadas e dificilmente podem ser transferidas para outros campos tais como o processamento digital de imagens de satélite. Segundo Schiewe e Tufte (2001) as principais razões para isso são:

- ◆ Em dados multiespectrais, e em parte também em dados de múltipla-escala, não só a complexidade, mas também a redundância e, portanto, a fiabilidade dos métodos aumenta de forma clara;

- ◆ Há uma grande variedade de dados auxiliares (*e.g.* provenientes de sistemas SIG) que estão disponíveis e podem ser integrados no processo;
- ◆ Em comparação com outras aplicações, os vários objetos com propriedades heterogêneas (em relação à forma, comportamento espectral, textura, etc.) têm que ser classificados e a integração dessas diferentes propriedades ainda não é devidamente tomada em consideração;
- ◆ Encontram-se especialmente objetos de diferentes dimensões e os métodos existentes não permitem aplicações adequadas para lidar com dados de múltipla-escala.

Como consequência destes requisitos, o *software* para o tratamento baseado em objeto de dados provenientes de detecção remota deve ser capaz de tratar simultaneamente dados de diferentes fontes, deve ser possível aplicar várias estratégias de segmentação, dependendo do objetivo, e devem existir em paralelo diferentes níveis de escala de segmentação, em virtude de numa imagem de satélite pontificarem diversos objetos heterogêneos de diferentes dimensões. Schiewe (2002) catalogou estes três requisitos como multifonte, multimétodo e multi-escala.

No campo da detecção remota, o primeiro *software* comercial de análise de imagem baseada em objetos (inicialmente pensado para o tratamento de imagens médicas), o eCognition® da *Definiens Imaging*, está no mercado desde o ano 2000. Neste *software*, está implementado um algoritmo de segmentação multiresolução. Além deste, existem atualmente no mercado vários módulos de segmentação que podem ser integrados em programas de detecção remota já existentes. De seguida, será primeiramente avaliado de forma breve o desempenho dos atuais algoritmos de segmentação e ir-se-á verificar se, e como, os requisitos acima mencionados para um processo de segmentação são respeitados.

4.4.3. Desempenho do algoritmo

Neubert e Meinel (2003) efetuaram uma comparação entre diferentes programas de segmentação. Primeiro comparam genericamente uma seleção de

algoritmos de segmentação atualmente disponíveis no mercado e determinam a qualidade dos resultados de segmentação com base em dados multiespectrais de muito alta resolução, *i.e.*, dados IKONOS multiespectrais fundidos com a banda Pancromática (Pan). Os programas selecionados para a comparação foram:

- ◆ eCognition® (*Definiens Imaging*);
- ◆ *Data Dissection Tools* (INCITE, Universidade de Stirling);
- ◆ CAESAR (n.a. *Software*);
- ◆ InfoPACK (InfoSar);
- ◆ *Image Segmentation* para *Erdas Imagine (Remote Sensing Application Center)*;
- ◆ *Minimum Entropy Approach to Adaptive Image Polygonization* (Rheinische Friedrich-Wilhelms, Universidade de Bona, Instituto de Informática).

As segmentações foram geradas usando duas regiões teste. O objetivo foi extrair os limites dos objetos relevantes de uso e ocupação do solo. Uma boa segmentação é alcançada quando o máximo possível de áreas heterogêneas são corretamente demarcadas e, por outro lado, as áreas homogêneas não são excessivamente segmentadas em subsegmentos (*oversegmentation*), *i.e.*, sobre-segmentação. Além disso, os critérios de forma determinados devem ajustar-se tanto quanto possível com as dimensões das áreas de referência.

Na sua comparação, Neubert e Meinel (2003) chegaram à conclusão de que o *software* eCognition® providencia bons resultados e oferece grande potencial devido à segmentação multi-escala e à possibilidade de classificação de imagens baseada em lógica difusa. Os autores enfatizam a reprodutibilidade da segmentação e a diversidade de *interfaces* com outros sistemas de SIG e DR. No entanto, apesar dos bons resultados, em algumas situações ainda ocorre a formação de segmentos delimitados irregularmente. O InfoPACK também obteve bons resultados, embora tenha uma tendência para a sobre-segmentação e a formação de segmentos alongados nas transições. Os resultados das outras abordagens não se aproximaram em termos de qualidade dos destes dois programas (Neubert e Meinel, 2003).

4.4.4. Reprodutibilidade dos resultados

Um aspecto importante e decisivo de um algoritmo de segmentação de alto desempenho é a reprodutibilidade dos seus resultados. O resultado de uma segmentação deve ser reproduzível em qualquer momento. Este tipo de reprodutibilidade é dado a 100% pelo *software* eCognition®, como já mencionado por Neubert e Meinel (2003).

No entanto, podemos conceber ainda um outro tipo de reprodutibilidade – chamada reprodutibilidade independente. Nesse caso, um objeto que se manteve inalterado em duas cenas do satélite de datas diferentes deve ser segmentado de forma idêntica e identificado como o mesmo objeto. Isto permitiria uma deteção de alterações realista assente numa classificação baseada em objetos. No entanto, neste momento esta reprodutibilidade independente ainda não é um dado adquirido. A razão é que, por um lado, a dependência da segmentação relativamente a vários parâmetros de aquisição da imagem. Parte desses parâmetros variam significativamente em diferentes intervalos de tempo, *e.g.* radiometria, iluminação ou diferentes ângulos de sensor. Esta situação conduz a uma segmentação diferente de objetos idênticos em cenas individuais multitemporais.

Outra razão para a falta de reprodutibilidade independente é o modo de funcionamento da segmentação multi-escala utilizado, que determina os seus pontos de partida com base em todas as informações disponíveis sobre a imagem. Assim, a segmentação de uma cena de um determinado satélite ou de um subconjunto dessa mesma cena conduzem a resultados diferentes para os limites do objeto. Uma vez que a população superior (relação hierárquica de pai para filho) na comparação de uma cena com um segmento da cena é diferente, são escolhidos diferentes pontos de partida. Isso pode levar a uma segmentação diferente, por exemplo, de um mesmo edifício. Esta realidade resulta em alterações artificiais causadas pelo processo de segmentação, o que reduz a qualidade do resultado de uma deteção de alterações com base numa comparação pura de classificações.

A utilização da segmentação independente na análise de imagens baseada em objetos é presentemente um requerimento bastante utópico, uma vez que o problema das alterações nas condições de aquisição em imagens multitemporais já vem do tempo

dos métodos de classificação baseados no píxel. No entanto, no contexto da classificação multitemporal esta questão deve ser vista como uma restrição. Dado que o primeiro passo na classificação baseada em objetos é a segmentação, todos os outros resultados obtidos são dependentes do seu desempenho.

Uma solução parcial para este problema geral é proceder a um pré-processamento adequado dos dados de satélite, onde no decurso de várias etapas as cenas individuais são compatibilizadas tão bem quanto possível. Como regra, esta etapa precede todas as outras medidas e os métodos aplicados podem variar.

Pode ainda ser tida em conta uma combinação entre classificações baseadas no píxel e classificações baseadas em objetos, uma vez que o problema dos limites dos objetos segmentados de forma diferente não se coloca nas classificações baseadas no píxel. Também seria concebível a utilização de um novo tipo de algoritmo de *cluster* ou segmentação. Este algoritmo teria que prestar mais atenção a outras características, como as relacionadas com forma ou posição dos objetos na imagem e ser capaz de extrair objetos da imagem de forma seletiva. Dado que o desenvolvimento de tal algoritmo está para além do âmbito desta dissertação, as outras alternativas supramencionadas são aplicadas e é utilizado o algoritmo de segmentação multi-escala existente do *software* eCognition®.

O *software* eCognition® desenvolvido pela *Definiens Imaging* em 1999 e continuamente desenvolvido desde então cumpre as exigências importantes requeridas para um produto poder ser utilizado em deteção remota, nomeadamente:

- ◆ Segmentação multi-escala que pode ser influenciada pelo utilizador;
- ◆ Possibilidade de incorporar dados adicionais bastante diversos;
- ◆ Integrar diferentes características heterogéneas na classificação.

Estes três pontos satisfazem os aspetos multifonte, multimétodo e multi-escala exigidos por Schiewe (2002). Pode, portanto, considerar-se que o algoritmo de segmentação usado é atualmente um dos algoritmos mais eficientes em deteção remota.

4.4.5. Modelação semântica e classificação

Um objeto pode ser descrito por características tais como a sua assinatura espectral (*cf.* secção 4.3), forma, tamanho, textura e relações de vizinhança com outros objetos. Essas características representativas permitem uma posterior classificação em classes de objetos. Na modelação semântica, estas características típicas das classes de objeto devem em primeiro lugar ser determinadas e combinadas num modelo semântico.

O modelo é construído como uma rede semântica baseada em regras, que constitui uma forma de apresentação do conhecimento. A vantagem dessa rede é a possibilidade de existir um arranjo hierárquico e a articulação de toda a informação existente sobre os objetos. No modelo as classes individuais de objetos são denominadas de nós. Por seu turno, os conceitos fornecem a descrição genérica das classes de objeto. A aplicação destes conceitos às cenas do satélite em questão é apelidada de instâncias (Tönjes, 1999).

Os nós da rede estão ligados uns aos outros pelas margens. Estas margens descrevem as relações entre objetos vizinhos, de nível inferior ou superior. Em termos técnicos, estas relações podem ser repartidas por relações hierárquicas, topológicas, opcionais e obrigatórias. As relações hierárquicas e topológicas resultam das relações estruturais entre os objetos, enquanto as relações obrigatórias e opcionais são determinadas através do número mínimo e máximo nas relações da rede.

As características de uma classe de objeto são descritas pelos seus atributos. Estes possuem um valor (medido) e um intervalo de valores para os quais os métodos de cálculo são alocados. O conhecimento inerente em uma rede semântica pode ser separado em conhecimentos processuais e declarado. O conhecimento declarado contém os conceitos e as relações, ao passo que o conhecimento processual compreende os métodos para calcular os atributos do conceito e para avaliar os próprios conceitos e as relações. Portanto, o conhecimento processual, determina a ordem da análise, a qual pode ser apresentada como um conjunto de regras.

Esta base de regras contém uma parte relativa à condição e outra sobre a ação. A condição verifica se há um novo estado de interpretação para o nó vizinho na rede semântica e a parte de ação nesse estado adapta-se em conformidade. Se houver várias

condições a caracterizar uma classe de objeto, eles são ligados por operadores lógicos, *e.g.* e (AND), ou (OR), não (NOT), etc. Para uma descrição detalhada de redes semânticas, existe disponível uma extensa literatura sobre este tema, como Förstner *et al.* (1999), Sagerer e Niemann (1997), Tönjes (1999) e Tönjes *et al.* (1999).

Os modelos semânticos utilizados nesta dissertação são configurados como uma rede de classes de objeto com base numa base de regras, como referido nos parágrafos anteriores. As classes de objeto são descritas por características representativas. A classificação semântica determina se um objeto pertence, ou não, a uma determinada classe de objeto com base na sua importância. Uma função de classificação determina um nível de confiança, comparando as características individuais do objeto a ser classificado com os atributos. Este nível de confiança fornece informações sobre se o objeto pertence a uma classe, o que conduz a que a função de classificação também seja denominada de função de associação. A associação pode ser determinada através de várias abordagens. Uma das mais amplamente utilizadas são os modelos de probabilidade Bayesiana (Haralick e Shapiro, 1993), a teoria de evidências de Dempster e Shafer (Kunz *et al.*, 1998) ou os modelos baseados em lógica difusa (Baatz e Schäpe, 1999; 2000).

Capítulo 5 - Classificação (semi)automática baseada em objetos

A deteção remota tem sido considerada como uma opção viável para o processamento de imagens e extração eficaz de dados (Weiers *et al.*, 2004 em Díaz Varela *et al.*, 2007). Dentro deste contexto, a classificação baseada em objecto tem exibido vantagens em relação às técnicas de classificação tradicionais, nomeadamente na exploração exaustiva e sistemática da ocupação do solo e da aquisição de dados periódicos.

O recurso à computação pretende facilitar e por vezes substituir de forma mais eficiente o trabalho humano. A aproximação à capacidade do sistema ocular, de categorizar uma imagem e detetar determinados elementos, tem sido um dos focos principais da Deteção Remota.

Sendo utilizada maioritariamente para a categorização da ocupação e uso do solo, esta técnica defronta-se com a crescente necessidade de atualização da informação e criação constante de cartografia, traduzindo-se tipicamente num alto consumo de tempo e de recursos, e conseqüentemente crescendo a necessidade de computar todos os processos possíveis.

No entanto, apesar dos esforços e desenvolvimentos conseguidos nas técnicas de deteção remota, o objetivo principal no processamento de imagens ainda não foi alcançado. A automatização dos processos de extração de informação é defrontada por inúmeros obstáculos, desde a multitemporalidade da informação, diferentes binómios satélite/sensor, alteração da área de estudo, entre outros. Porém, têm sido apresentadas algumas metodologias que de certa forma conseguem classificar uma imagem na totalidade ou uma classe em particular, através de processos semiautomáticos. Estes processos são muitas vezes referidos como métodos de classificação automática por responderem a alguns dos obstáculos mencionados anteriormente, mas a realidade é que no processo de categorização é seguida muitas vezes uma abordagem supervisionada. Esta abordagem, assume que sejam criadas áreas de treino, *i.e.*, amostras dos elementos que se pretende classificar, e através destas áreas recorre-se a algoritmos e/ou métodos matemáticos/estatísticos com a

capacidade de categorizar uma determinada imagem ou classe. De forma, a exemplificar em que estado se encontra a noção de automatização na classificação de imagens, serão apresentados de seguida alguns trabalhos cujo objetivo se traduz no colmatar desta problemática.

5.1. Contextualização metodológica

Shackelford e Davis (2003) apresentaram uma das primeiras tentativas para comparar classificações obtidas por métodos baseados nos píxeis e em objetos (*cf.* Flanders *et al.*, 2003 e Ehlers *et al.*, 2006), recorrendo a uma metodologia assente na lógica difusa para melhorar a exatidão da classificação de imagens de satélite multiespectrais de grande resolução em contexto urbano e suburbano.

Posteriormente, um grande número de estudos publicados em periódicos científicos enfatiza as melhorias que OBIA oferece em comparação com as análises baseadas no píxel. Por exemplo, Yu *et al.* (2006) criaram um inventário abrangente de vegetação para uma área no norte da Califórnia e conseguiram demonstrar empiricamente que a abordagem OBIA permitiu superar o problema do efeito sal-e-pimenta (*salt-and-pepper*), tão característico dos resultados das classificações tradicionais baseadas no píxel (Blaschke *et al.*, 2000).

Frequentemente tem sido afirmado que os métodos OBIA são adequados para superar o efeito sal-e-pimenta, por exemplo, graças às melhorias na segmentação de imagem, as abordagens baseadas em objetos podem ser usadas para delinear e classificar de forma eficientemente a ocupação do solo (Duveiller *et al.*, 2008). Também parece claro que as técnicas de processamento baseadas em objetos estão a tornar-se mais populares que os métodos mais conservadores baseados no píxel (Gamanya *et al.*, 2009).

Desde o seu aparecimento, que as aplicações em OBIA têm-se caracterizado pela sua diversidade, quer ao nível dos dados utilizados, quer ao nível dos objetivos da aplicação e da abordagem metodológica adotada. Na impossibilidade de os referir a todos apresenta-se a Tabela 5.1 com o intuito de fornecer uma visão geral do enquadramento da OBIA na ciência da Deteção Remota. Parece possível arriscar a

afirmação de que as vantagens específicas da abordagem OBIA são potenciadas quando implantadas em imagens de muito grande resolução espacial (al Khudairy *et al.*, 2005), apesar de se encontrarem algumas abordagens regionais aplicadas a outras situações, *e.g.* para imagens do Landsat, e outros dados de baixa ou média resolução (Duveiller *et al.*, 2008; Myint *et al.*, 2008; Jobin *et al.*, 2008).

Tabela 5.1 - Desenvolvimentos recentes no âmbito da OBIA

	Imagens	Aplicações		
		Vegetação	Urbano	Uso e Ocupação do Solo
Laser	Lidar	Maier <i>et al.</i> (2008); Pascual <i>et al.</i> (2008)		
	Scanner laser aerotransportado		Aubrecht <i>et al.</i> (2008)	
Imagens de muito alta resolução espacial	IKONOS		Bhaskaran, S., Paramananda, S., e Ramnarayan, M. (2010)	Shiba and Itaya (2006); Lackner and Conway (2008); Shackelford and Davis (2003)
	Quick Bird	Mallinis <i>et al.</i> (2008); Johansen <i>et al.</i> (2007)	Freire <i>et al.</i> (2014)	Shiba and Itaya (2006); Mo <i>et al.</i> (2007); Ivits and Koch (2002); Ivits <i>et al.</i> (2005)
	Ortofotomapas Fotografias Aéreas	Wiseman <i>et al.</i> (2009); Zhou and Troy (2008)	Jacquin <i>et al.</i> (2008); Magarotto <i>et al.</i> (2015)	Krause <i>et al.</i> (2004); Ivits e Koch (2002); Ivits <i>et al.</i> (2005)
Imagens de resolução espacial média/alta	Landsat			Ivits and Koch (2002); Ivits <i>et al.</i> (2005)
	Indian Remote Sensing (IRS)			Ivits and Koch (2002); Ivits <i>et al.</i> (2005)
	Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) satélite Terra			Chen <i>et al.</i> (2007)
Hiperespectrais	Compact Airborne Spectrographic Imager (CASI)	Bunting and Lucas (2006)		

Chen *et al.* (2007) demonstraram o potencial da OBIA para mapear a ocupação do solo urbano para a cidade de Pequim usando dados do sensor *Advanced Spaceborne Thermal Emission and Reflection Radiometer* (ASTER) com uma precisão relativamente alta (15, 30 e 90 metros). Ivits e Koch (2002) e Ivits *et al.* (2005) analisaram padrões de

paisagem para 96 parcelas de amostra na Suíça. Os padrões de paisagem foram quantificados com base na integração de imagens dos satélites Landsat, *Indian Remote Sensing* (IRS) (cerca de 23 metros de resolução espacial) e QuickBird, com fotografias aéreas.

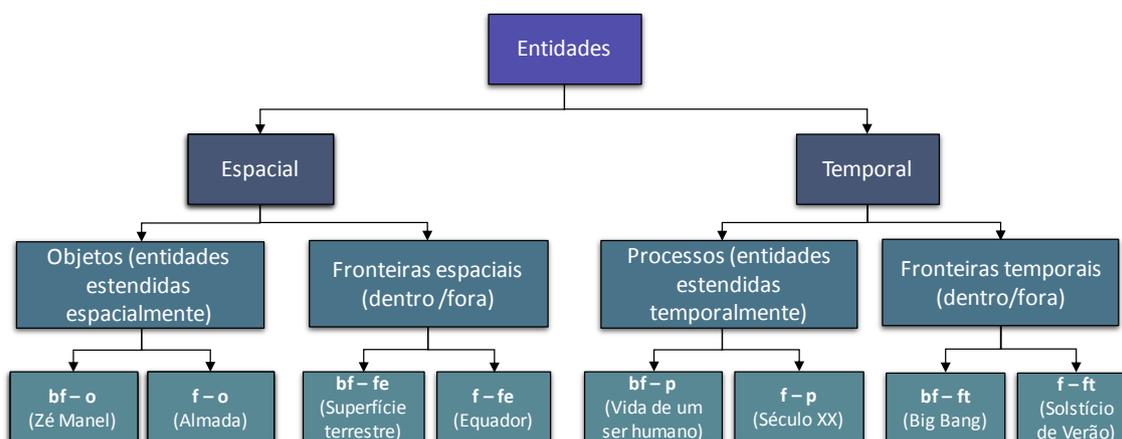
No entanto, Pinho *et al.* (2012) referem as dificuldades encontradas na classificação de uma área urbana, com uma imagem de muito alta resolução IKONOS. Os autores decorrem que a análise das classes urbanas, com um procedimento orientado para objeto, mesmo que vantajosa, é morosa e complexa devido às dificuldades de processamento relacionadas com a segmentação de imagens, que se traduz num grande número de objetos a ser classificado. Deste modo afigura-se interessante explorar a aplicação da OBIA a dados de média/alta resolução de forma a estabelecer uma metodologia eficaz de classificação de ocupação do solo a nível regional que seja reproduzível em diferentes contextos temporais com uma intervenção mínima por parte do operador.

5.2. O conceito de Objeto

Numa perspetiva lata, Smith (1998), define objeto, afirmando que num contexto de uma geo-ontologia, um objeto e uma entidade devem compreender regiões, limites, parcelas do território, corpos de água, estradas, edifícios, pontes e aí por diante, bem como partes ou agregações de todos eles. Contudo, para proceder à identificação e demarcação de um objeto no espaço, é primeiro necessário determinar as suas fronteiras, as quais apresentam duas naturezas distintas, as *bona fide boundaries* e as *fiat boundaries* (Smith, 2001). Ou seja, para os dados geográficos, uma geo-ontologia tem dois tipos básicos de conceitos, os que correspondem a fenómenos físicos do mundo real e os que são criados para representar entidades sociais e institucionais (Smith e Mark, 1998; Fonseca *et al.*, 2003).

As primeiras - *bona fide boundaries* - existem independentemente dos atos de cognição humana, como seja por exemplo um rio e as segundas - *fiat boundaries* -

resultam apenas de atos de decisão humana, como sejam os limites administrativos². Deve-se, no entanto, referir, que muitas vezes são necessárias *Bona Fide Boundaries* para se encontrarem *Fiat Boundaries*, uma vez que as primeiras servem como marcas territoriais para a delimitação das segundas. Desta forma, e resultando da tipologia das suas fronteiras, podemos ter objetos/entidades *bona Fide* e objetos/entidades *fiat*, os quais apresentam uma forte correlação com a noção de objeto geográfico, decorrente, por sua vez, da noção de espaço geográfico. Assim temos, o objeto geográfico no espaço geográfico, *i.e.*, objeto representado, e o objeto nas representações espaciais, *i.e.*, objeto representativo. A Figura 5.1 esquematiza a taxonomia dos dois tipos de entidades propostas por Smith (2001).



bf = bona fide; f = fiat; o = objeto; p = processo; fe = fronteira espacial; ft = fronteira temporal

Figura 5.1 - Taxonomia de entidades *bona fide* e entidades *fiat* (adaptado de Smith, 2001)

Chamamos os primeiros - *bona fide* - de conceitos físicos e os segundos - *fiat* - de conceitos sociais. Muito embora todos os conceitos resultem do uso compartilhado da linguagem, há uma diferença entre conceitos que se referem ao mundo físico e aqueles que resultam de convenções humanas. A geo-ontologia faz a diferenciação entre conceitos associados a entidades que podem ser individualizadas e identificadas nominalmente, *e.g.* edifícios, e aquelas que variam de forma contínua no espaço, *e.g.* declives.

² Nalguns casos, os limites administrativos podem resultar de uma mistura de *bona fide boundaries* e *fiat boundaries*, como é o caso da linha de costa.

Os conceitos físicos podem ser subdivididos em dois pontos. O primeiro abarca os conceitos associados a entidades individualizáveis, que possuem uma fronteira bem definida a partir de diferenciações qualitativas ou descontinuidades na natureza. Designados como objetos *bona fide*. A sua existência decorre de nossa necessidade de dar nomes aos elementos do mundo natural. Por exemplo, embora a superfície da Terra apresente uma variação contínua no espaço, a nossa percepção do espaço depende da associação de nomes especiais a variações bem definidas no terreno. Daí emergem conceitos como serra, vale e desfiladeiro. O segundo, por seu turno, abrange os conceitos associados a entidades que tem variação contínua no espaço, associadas aos fenômenos do mundo natural, não estando em princípio limitadas por fronteiras. Chamamos estes conceitos de gradientes físicos, onde o termo “gradiente” está associado a qualquer grandeza que varia continuamente. Neste contexto estão incluídos a temperatura, a altimetria, os declives e a poluição.

Por outro lado, os conceitos sociais também podem ser subdivididos em duas classes. A primeira, a dos conceitos que descrevem entidades individuais criadas por leis e por ações humanas. Estas entidades possuem uma fronteira que as distingue do contexto envolvente e têm uma identidade única. A sua existência depende normalmente de um registo legal. Designadas como indivíduos *fiat*, incluem conceitos como lotes, municípios e países. A segunda, a dos conceitos descrevendo entidades que apresentam uma variação contínua no espaço, associadas a convenções sociais. Pode-se avançar como exemplo o caso da pobreza, conceito socialmente definido que ocorre no espaço de forma ininterrupta (em cada lugar há tipos diferentes de pobreza). Estes conceitos são entendidos como gradientes sociais e incluem, por exemplo, a exclusão social, a segregação urbana e o desenvolvimento humano.

Através da noção de *bona fide*, depreende-se que existe uma certa similaridade com a ideia de objeto geográfico representado, na medida em que será aquele que existe independentemente dos atos de cognição humana. Contudo, ao nível da criação de modelos, os objetos representados também poderão ser *fiat*, por exemplo, o conceito de espaço verde urbano. O que diferencia uma área de vegetação, considerada urbana de uma outra não urbana, em que ambas têm uma área igual e as mesmas espécies vegetais? Poderá ser provavelmente a proximidade a uma área de

construído, ou a percentagem de área rodeada por construído (Baatz *et al.*, 2003). A noção geral de objeto representativo terá a sua tradução no conceito *fiat*, o qual, como já foi afirmado, resulta de atos de cognição humana e por essa razão é o aplicado nos modelos de classificação de uso e ocupação do solo.

Dentro da realidade física, aquela que é mais pertinente no contexto deste trabalho existem duas classes, gerais e opostas, de modelos de informação geográfica (Chrisman, 1975, 1978; Peuquet, 1984). A classe dos modelos baseados em campos, *i.e.*, entidades com variação contínua, trata esta informação como coleções de distribuições espaciais, onde cada distribuição pode ser formalizada como uma função matemática de uma estrutura espacial, como por exemplo uma matriz regular colocada sobre um modelo idealizado da superfície terrestre. A classe dos modelos baseados em objetos, *i.e.*, entidades individualizáveis (objetos *bona fide*) trata o espaço de informação como estando preenchido por entidades, discretas e identificáveis, cada uma das quais georreferenciada. Estes dois tipos de modelo resultam em duas abordagens opostas, mais precisamente a vetorial e a matricial. Couclelis (1992) observa que a discussão campo-objeto no âmbito dos SIG se assemelha a uma controvérsia bastante mais fundamental da filosofia da ciência, que é a entre as ontologias atômica e *plenum*. Isto manifesta-se, por exemplo, nas teorias físicas do início do século XX muito utilizadas em deteção remota, mais precisamente a das partículas (atômica, baseada em objetos) versus a das ondas (*plenum*, baseada em campos).

A identificação dos fenómenos urbanos e a sua delimitação no espaço, recorrendo à deteção remota, envolve dois passos principais:

- i. Determinar a variabilidade morfológica dos objetos;
- ii. Delimitar entidades/objetos urbanos que sejam relevantes.

Na análise visual de imagem, o olho humano consegue distinguir os objetos, porque associa a resposta espectral à forma. A forma ou geometria é assim, um dos atributos mais relevantes para a diferenciação dos objetos representados na imagem, em relação a outros. Contudo, a quantificação que o atributo forma, numa abordagem de análise de imagem orientada a objeto, é bastante complexa, quer ao nível teórico, quer ao nível prático, na medida em que as entidades da superfície terrestre são

entendidas como objetos compósitos, assim como os objetos seus representativos na imagem. Isto é, são objetos compostos pela relação entre o todo e as suas partes, a qual pode ser quantificada. Assim, sendo a forma um dos atributos que caracteriza o objeto compósito, esta apresentará, também, diferentes configurações - a geometria do todo e a geometria das partes que o constituem, pelo que, a forma de um objeto compósito será o conjunto das formas das suas partes (Figura 5.2).

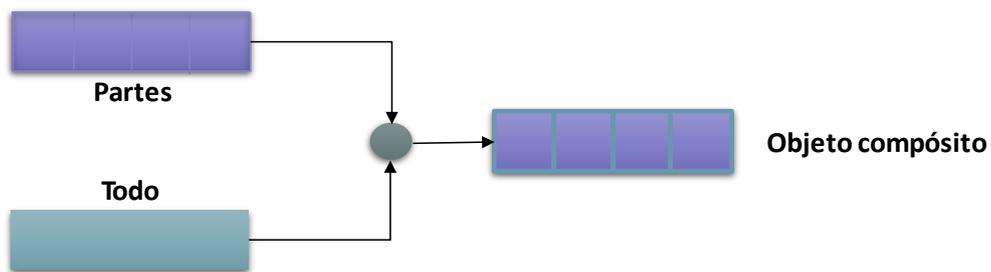


Figura 5.2 - Objeto compósito

Da simplificação do objeto compósito fica implícita a necessidade de se trabalhar os dados com diferentes escalas de análise, na medida em que a escala de percepção espacial do todo é diferente da escala de percepção espacial das partes. Em estudos de análise territorial apercebemo-nos da existência de objetos compósitos, quando, por exemplo, se procura, simultaneamente, a delimitação (o todo) e a morfologia (as partes) do objeto. A dicotomia entre as escalas de percepção espacial assume um papel determinante na operacionalização dos objetos a classificar numa imagem.

5.3. Classificação de Imagem Baseada em Objeto (OBIA)

A classificação de imagens de satélite é uma das aplicações diretas mais frequentemente utilizadas no estudo de uso e ocupação do solo. É um processo de extração de informações em imagens que possibilita reconhecer padrões e objetos homogêneos, permitindo assim mapear áreas da superfície terrestre correspondentes aos temas de interesse. Este processo consiste em, "(...) a partir dos valores do

contador digital de uma imagem em várias bandas, originar uma nova imagem, mais simples, em que cada píxel está associado a uma categoria ou classe (...)” (Centeno, 2004), permitindo sintetizar a variabilidade e complexidade inerentes a uma paisagem num número limitado de classes definidas pelo produtor.

Tradicionalmente as técnicas de análise de imagens são baseadas nos píxeis, onde apenas os seus atributos espectrais são utilizados (Hester *et al.*, 2008), sendo exploradas as suas diferenças nos elementos a ser extraídos. No uso do píxel, ocorre uma perda de significado, pois este não é associável a um elemento da imagem, mas sim à composição do mesmo. O píxel, “(...) é pouco mais do que uma unidade discreta e independente para a qual as relações (...) são dadas apenas por um tratamento estatístico do seu valor digital.” (Encarnação, 2004). Porém, em situações específicas, existe a necessidade de classificar grupos contínuos de píxeis, homogêneos e que se assemelham de perto aos recursos terrestres (Kampouraki *et al.*, 2008). Para tal, recorre-se a uma classificação baseada no objeto, onde, além dos atributos espectrais é possível utilizar em conjunto atributos não espectrais, como a proximidade, geometria (Chubey *et al.*, 2006), forma, textura e morfologia.

Esta nova abordagem de tratar as imagens de satélite e de analisar uma área através de elementos de dimensões maiores que a do píxel, os objetos, transformando-os nos elementos primitivos da imagem, é referida como Classificação Baseada em Objeto.

A abordagem baseada em objeto é vista como uma forma de integração entre a fotointerpretação que recorre invariavelmente às primitivas visuais, no reconhecimento dos objetos na imagem, da técnica do utilizador e da sua experiência de campo. “A subjetividade da interpretação humana está sempre presente. Porém, em toda a subjetividade, existe a objetividade do que é comum a todos os seres humanos – as bases com que são construídos significados” (Encarnação, 2004).

O ser humano não interpreta a informação presente no solo através da tradução dos níveis de cor de cada píxel, mas sim através de uma representação aproximada da realidade, ou seja, pela construção de objetos que além da informação espectral contam com informação de contexto espacial. “Um píxel não pode apresentar uma correspondência válida a um objeto da vida real, mas um objeto pode” (Lang, 2008).

Assim, o facto de “(...) a abordagem orientada por objeto ter uma maior aproximação à forma como o indivíduo constrói objetos, através da cognição humana e independentemente da área geográfica” (Encarnação, 2004), constitui a melhor metodologia de classificação a ser utilizada.

5.4. OBIA versus GEOBIA

A noção de OBIA está relacionada com conceitos do *software* de classificação de imagens baseada em objeto e à manipulação de objetos em ambiente SIG (Bian, 2007). É de certa forma consensual (Blaschke *et al.*, 2000; Blaschke e Strobl, 2001; Schiewe, 2002; Flanders *et al.*, 2003; Benz *et al.*, 2004; Liu *et al.*, 2006; Navulur, 2007; Lang, 2008) que a OBIA assenta nas técnicas clássicas de segmentação, deteção de margens, extração de elementos e conceitos de classificação, que nas últimas décadas têm vindo a ser usados na análise de imagens de deteção remota (Kettig e Landgrebe, 1976; Haralick, 1983; McKeown *et al.*, 1989; Lobo *et al.*, 1996; Wulder, 1998; Aplin *et al.*, 1999; Baltsavias, 2004).

No entanto, o seu surgimento forneceu uma nova ponte entre os conceitos de espaço aplicados na análise multi-escala da paisagem (Wu, 1999; Hay *et al.*, 2001; Wu e David, 2002; Burnett e Blaschke, 2003), os sistemas de informação geográfica (Câmara *et al.*, 1996; Yu *et al.*, 2006), a Ciência da Informação Geográfica (CIG) (Goodchild, 1992, 2004) e a sinergia entre imagem-objetos e as suas características radiométricas e análises em dados de observação da terra (Jobin *et al.*, 2008; Stow *et al.*, 2008; Tiede *et al.*, 2008; Trias-Sanz *et al.*, 2008; Weinke *et al.*, 2008).

Nos últimos anos, surgiu a discussão crítica no que diz respeito à questão de se o espaço geográfico deve ou não ser incluído no conceito (*cf.* Hay e Castilla, 2008; Castilla *et al.*, 2008; Lang, 2008). Hay e Castilla (2008) argumentam que a designação correta deverá ser *Geographic Object Based Image Analysis* (GEOBIA), pois só nesse caso será evidente que representa uma subdisciplina da CIG. Com efeito, o termo OBIA pode ser muito amplo, visto que se para muitos investigadores em deteção remota, especialistas em SIG, e nas disciplinas com base espacial, os dados das imagens representam partes da superfície da terra, tal associação pode não ser tão linear por parte de investigadores

na área da visão computacional, ciências de materiais ou de imagem biomédica, que também recorrem à OBIA.

Além disso, muitos poucos pioneiros da OBIA usavam o termo “baseado em objeto”. Alguns autores utilizavam “orientado a objeto” (Blaschke *et al.*, 2000 e Benz *et al.*, 2004), tendo alguns deles optado mais tarde por usar a designação “baseado em objeto”, enquanto outros permaneceram fiéis ao termo “orientado a objeto” (*e.g.* Navulur, 2007). Até agora foi assumido que a maioria dos autores prefere usar o termo “baseado” em detrimento de “orientado”, o qual pode ser ligado ao paradigma de programação orientada a (ou para) objetos (*cf.* Hay e Castilla, 2008).

Uma vez que estes dois debates continuam em curso, optou-se por reconhecer os dois termos como igualmente apropriados, mas recorrer por uma questão de uso de simplicidade ao título do livro referência neste campo (Blaschke *et al.*, 2008), bem como dos dois predecessores (Blaschke e Kux, 2005), e utilizar o acrónimo OBIA nesta dissertação.

5.4.1. Construção de Objetos

No *software* de classificação utilizado neste trabalho (eCognition®) os objetos são construídos por segmentação multiresolução, uma técnica de crescimento de regiões. Neste processo toda a imagem é convertida em múltiplos objetos, formados por conjuntos de píxeis espectral e espacialmente similares. Para cada objeto é associado além da informação espectral, características como a forma, tamanho, textura, relações de vizinhança, entre outros, uma vez que cada objeto é composto por múltiplos píxeis.

No eCognition® o processo de segmentação é uma técnica de fusão *bottom-up*. Primeiramente os píxeis são ligados para produzir objetos da imagem extraindo áreas homogéneas, (Kampouraki *et al.*, 2008) de seguida, em “(...) subsequentes passos, numerosos objetos pequenos são fundidos em maiores, minimizando a heterogeneidade ponderada dos objetos resultantes (...)” (Benz *et al.*, 2004 em Hese e Schmullius, 2008). Na Figura 5.3 encontra-se ilustrado o processo de segmentação de imagens por crescimento de regiões. Segundo Bins *et al.*, (1996) inicialmente, cada

célula corresponde a um píxel da imagem (Figura 5.3a), onde são escolhidas as células sementes (Figura 5.3b). De seguida, com base no critério de homogeneidade, cada célula semente é comparada com as células vizinhas e duas células vizinhas são agrupadas se o critério de similaridade for satisfeito (Figura 5.3c e Figura 5.3d). Nesta fase, decorre a formação de uma nova célula, que herda as propriedades das anteriores. As células continuam a ser agrupadas enquanto o critério de similaridade for satisfeito (Figura 5.3e e Figura 5.3f).

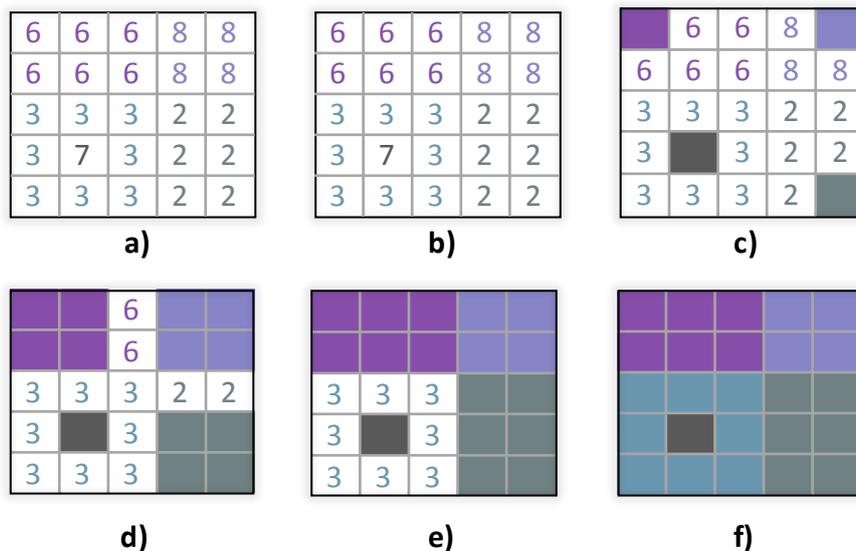


Figura 5.3 - Processo de segmentação de imagens por crescimento de regiões

A concluir, todos os algoritmos de crescimento de regiões apresentam uma sequência lógica que com início na definição de células sementes, a partir das quais regiões são construídas pela junção de vizinhos similares (Espindola, 2007). Assim, Zucker (1976) descreve as condições que devem ser respeitadas em qualquer algoritmo de segmentação. Segundo este autor, a divisão da imagem X em regiões homogéneas X_1, X_2, \dots, X_N , onde P é o predicado lógico que mede a homogeneidade de uma região processa-se segundo as seguintes condições (Espindola, 2007):

- ◆ As regiões X_1, X_2, \dots, X_N , devem ser compostas por uma sequência de pontos contíguos;
- ◆ $\bigcup_{i=1}^N X_i = X$ i.e., a segmentação deve ser completa;

- ◆ $X_i/X_j = \emptyset$ para todo o $i \neq j$, *i.e.*, todas as regiões devem ser distintas e separadas;
- ◆ $P(X_i)$ é verdadeira para $i=1,2,\dots,N$, *i.e.*, o atributo de homogeneidade deve ser satisfeito para cada região;
- ◆ $P(X_i \cup X_j)$ é falsa para $i \neq j$, onde X_i e X_j são adjacentes, *i.e.*, regiões vizinhas possuem atributos diferentes.

5.4.2. Parâmetros da segmentação

Segundo Haralick e Shapiro (1985), os objetos de uma segmentação devem ser uniformes e homogêneos. Para tal, aquando a aplicação do algoritmo de segmentação multiresolução podem ser definidos parâmetros de forma a aumentar a aproximação e correspondência entre os objetos da imagem e os da superfície terrestre (Woodcock e Harward, 1992).

A segmentação multiresolução é fomentada através de um processo heurístico de decisão, baseando-se num critério de fusão, determinado pela heterogeneidade ou homogeneidade das características espectrais e espaciais dos objetos da imagem. Na análise da semelhança entre objetos, além da heterogeneidade, o fator escala também é considerado.

O processo de segmentação multiresolução inicia-se com um píxel, considerado como um objeto, sendo comparado com os objetos vizinhos. Nesta fase é calculada a heterogeneidade dos objetos antes e depois da sua fusão, procurando-se obter a menor diferença para os dois momentos, e conseqüentemente a menor heterogeneidade entre os mesmos (5.1):

$$h_{dif} = h_m - \frac{(h_1 \cdot n_1 + h_2)}{n_2 + n_1}, \quad (5.1)$$

onde h_1 e h_2 representam a heterogeneidade e n_1 e n_2 a dimensão do objeto 1 e 2, respetivamente. Por fim, h_m traduz a heterogeneidade depois da fusão.

Assim, para o processo de fusão (f) (5.2) no critério geral de heterogeneidade são contidos dois componentes: a heterogeneidade espectral que tem em consideração a cor dos objetos (h_{cor}) (5.3)(5.4) e a heterogeneidade espacial, que tem em consideração a forma dos objetos (h_{forma}) (5.5). O processo de fusão traduz-se matematicamente como

$$f = w_{cor} \cdot h_{cor} + (1 - w_{cor}) \cdot h_{forma} . \quad (5.2)$$

Em (5.2) w_{cor} representa a importância relativa entre os componentes espacial e espectral, a qual é dada por

$$h_{cor} = \sum_c w_c \cdot \sigma_c , \quad (5.3)$$

onde w_c e σ_c representam, respetivamente, o peso dado e o desvio padrão dos valores espectrais de cada banda c . Deste modo (5.3) pode ser decomposta em (5.4),

$$h_{cor} = \sum_c w_c \left(n_{Obj3} \cdot \sigma_c^{Obj3} - \left(n_{Obj1} \cdot \sigma_c^{Obj1} + n_{Obj2} \cdot \sigma_c^{Obj2} \right) \right), \quad (5.4)$$

de forma que $Obj1$ é o objeto selecionado, $Obj2$ o vizinho analisado e $Obj3$ o objeto resultante da fusão de $Obj1$ com $Obj2$. Ainda, n representa a dimensão do objeto, σ_c^{Obj1} é o desvio padrão dos valores dos píxeis na banda c , considerando todos os píxeis pertencentes ao objeto $Objx$ e, por fim, n_{Objx} corresponde ao número de píxeis em $Objx$, para $x = 1, 2, 3$.

A heterogeneidade espacial (h_{forma}) (5.5) é influenciada pelos critérios de *compacidade* ($h_{compacidade}$) (5.6) e de *suavidade* ($h_{suavidade}$) (5.7). A heterogeneidade espacial é calculada de forma semelhante à heterogeneidade espectral, na medida em que, após o agrupamento de dois objetos, calcula-se a situação anterior e posterior à fusão, medindo a diferença de heterogeneidade,

$$h_{forma} = W_{compacidade} \cdot h_{compacidade} + (1 - W_{compacidade}) \cdot h_{compacidade} , \quad (5.5)$$

$$h_{compacidade} = n_{Obj3} \cdot \frac{l_{Obj3}}{\sqrt{n_{Obj3}}} - \left(n_{Obj1} \cdot \frac{l_{Obj1}}{\sqrt{n_{Obj1}}} + n_{Obj2} \cdot \frac{l_{Obj2}}{\sqrt{n_{Obj2}}} \right) , \quad (5.6)$$

$$h_{suavidade} = n_{Obj3} \cdot \frac{l_{Obj3}}{b_{Obj3}} - \left(n_{Obj1} \cdot \frac{l_{Obj1}}{b_{Obj1}} + n_{Obj2} \cdot \frac{l_{Obj2}}{b_{Obj2}} \right). \quad (5.7)$$

Nas equações (5.5)(5.8)(5.7), l_{Objx} é o perímetro dos objetos e b_{Objx} o perímetro da *bounding box*³, para $x = 1, 2, 3$.

O máximo de heterogeneidade permitida na construção de um objeto, *i.e.*, dimensão, é determinado pelo parâmetro de escala e influencia a dimensão do mesmo. No processo de *merge*⁴ de objetos é calculada a diferença entre a raiz quadrada do parâmetro de escala e o valor geral de *merge*. Se o valor da fusão for superior ao admitido pelo parâmetro de escala, o objeto não será fundido. Desta forma, quanto menor o parâmetro de escala maior será o número de objetos a construir, já que o grau de liberdade para aumentar a heterogeneidade do objeto é reduzido, resultando num objeto de pequena dimensão. Pelo contrário, se o parâmetro de escala for superior, menor será o número de objetos construídos, mas de maior dimensão. O parâmetro de escala pode assumir valores entre 1 (onde cada píxel é um objeto) e n , sendo n o número de píxeis da imagem (onde toda a imagem será um só objeto). O parâmetro de escala tem como função determinar o limite superior a partir do qual é permitida a alteração de heterogeneidade durante o processo de segmentação. (Baatz *et al.*, 2008).

Assim sendo, entende-se este parâmetro como um elemento de generalização automática de imagem, na medida em que mantendo inalteráveis os restantes parâmetros e alterando o parâmetro de escala, são produzidos objetos com diferentes formas e tamanhos, e por consequência com diferente significado.

A escolha do conjunto de parâmetros a utilizar é em função dos objetivos e das características das imagens, nomeadamente da variância da ocupação do solo registada e da resolução espacial e espectral. A variação do parâmetro de escala cria níveis de informação. Desta forma, o primeiro nível (Nível 1) será aquele com o parâmetro de escala mais baixo e conseqüentemente aquele em que os objetos se encontram mais

³ A *bounding box* é a forma mais comum de medição da extensão de uma imagem. Corresponde a um retângulo externo de uma imagem objeto, que envolve todos os píxeis com a menor extensão possível (Trimble, 2012).

⁴ Processo de fusão de vários píxeis ou objetos numa unidade.

próximos do píxel (relativamente aos restantes níveis) e, também por isso, aquele com um maior número de objetos.

Por exemplo, a construção dos níveis superiores (objetos compostos) pode obedecer aos objetos já construídos (sub-objetos), ou seja, como os objetos compostos resultam da fusão dos seus sub-objetos, os limites dos primeiros serão determinados pelos últimos (*cf.* secção 5.2). Na presença de vários níveis, um objeto que seja objeto composto de um de nível inferior, poderá ele próprio ser sub-objeto de um objeto de nível superior (Figura 5.4).

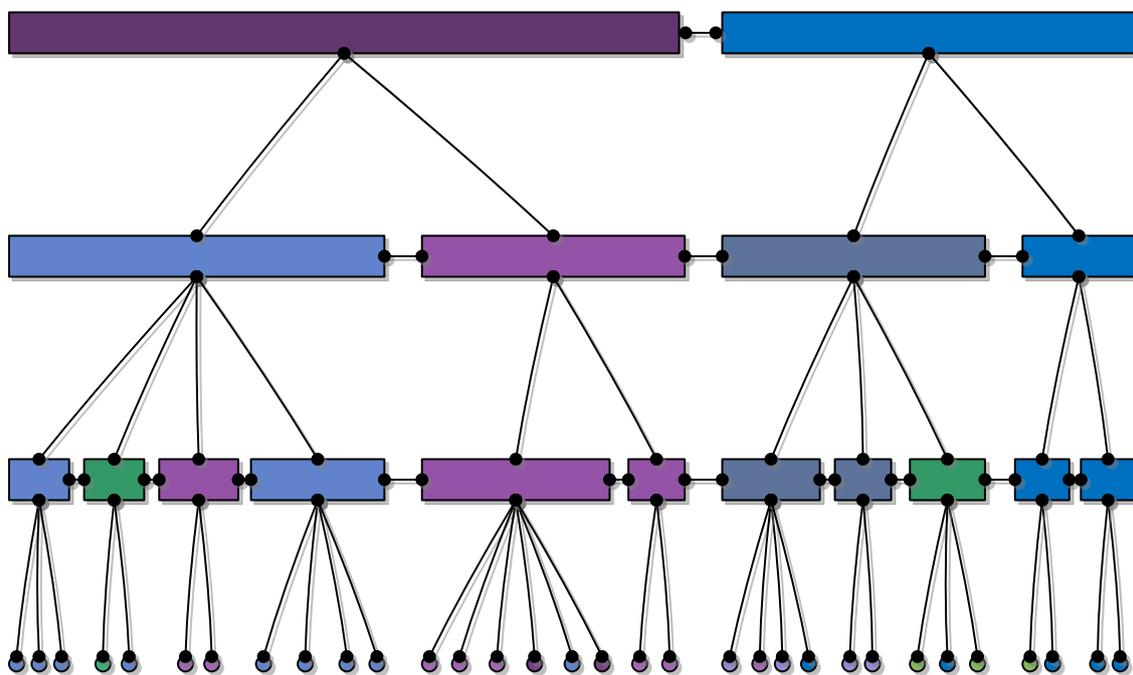


Figura 5.4 - Rede hierárquica de objetos (adaptado de Baatz *et al.*, 2003)

No processo de classificação dos objetos, a caracterização das classes necessita, à partida, de uma combinação de expressões, que possibilitem a construção de uma gramática de classificação. Quando estamos na presença de várias regras de decisão também podem ser utilizadas combinações de operadores, sem, contudo, se menosprezar o aumento da complexidade do sistema de classificação. De acordo com a natureza do operador, assim o valor de pertença final de um objeto a uma classe será

maior ou menor. Na Figura 5.5, encontra-se esquematizada a organização e hierarquia dos parâmetros possíveis de definir aquando a segmentação de uma imagem.

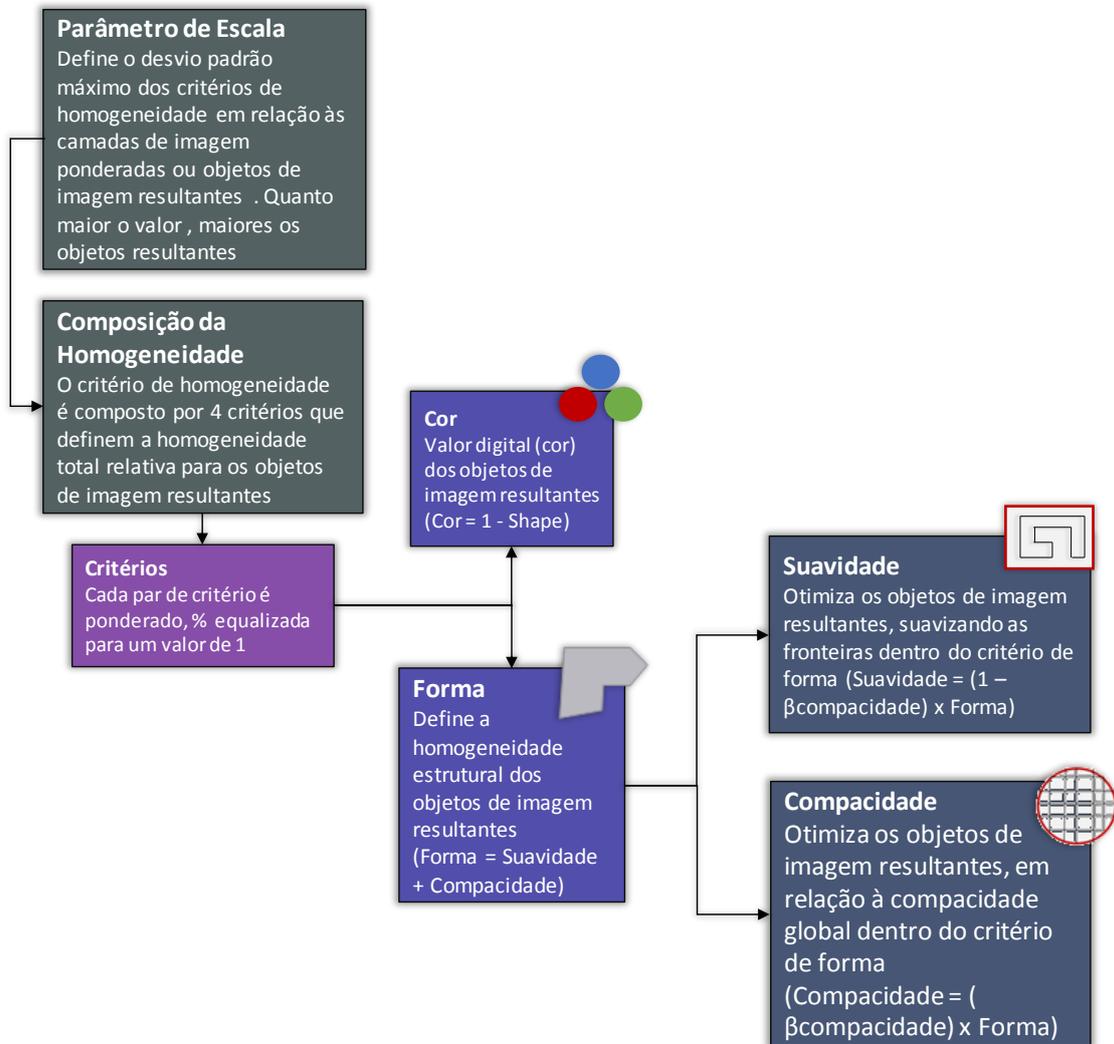


Figura 5.5 - Diagrama de fluxo dos parâmetros de segmentação multiresolução (Trimble, 2012)

De forma a entender melhor a relação entre os diferentes parâmetros utilizados e que alterações provocam na construção de objetos, foi elaborada uma breve descrição dos mesmos:

- ◆ **Escala** - Determina a heterogeneidade máxima permitida para se obter os objetos da imagem desejados e conseqüentemente a sua dimensão (Trimble, 2012). A variação deste parâmetro permite a construção de vários níveis de segmentação, variando a dimensão, forma e número de

objetos de imagem. “Estes níveis produzem uma rede hierárquica de objetos, a partir da qual um determinado objeto conhece os seus vizinhos, os seus sub e super-objetos” (Baatz e Benz *et al.*, 2003 em Encarnação, Tenedório e Rocha, 2004) A imagem deve ser segmentada numa escala, que permita identificar a menor característica de interesse. É muito importante o uso de tantos níveis de objetos quantos os necessários para que todos os objetos da imagem sejam explicitamente representados para o processo de classificação (Kampouraki *et al.*, 2008).

- ◆ **Forma e cor** - Modifica a relação entre os critérios de cor e forma, *i.e.*, ao alterar o valor do critério de forma, o de cor é juntamente modificado. Ao diminuir o valor do parâmetro forma, define-se que os valores espectrais dos objetos da imagem apresentam um contributo maior para o critério de homogeneidade. No caso de o critério de forma ter o valor máximo de 1, os objetos resultantes são otimizados para a homogeneidade espacial. No entanto, “o critério de forma não pode ter um valor maior do que 0,9, devido ao facto de que, sem a informação espectral da imagem” (Trimble, 2012) não seria utilizada a informação primária das imagens, reduzindo a qualidade da segmentação.
- ◆ **Compacidade e suavidade** - Utilizados para otimizar objetos de imagem, estes parâmetros apresentam uma influência ponderada. O critério de compacidade “(...) deve ser usado quando diferentes objetos de imagem que são bastante compactos, mas são separados de objetos não-compactos apenas por um contraste espectral relativamente fraco.” (Trimble, 2012). No que diz respeito ao critério de suavidade, o aumento do peso em oposição da compacidade, previne a complexidade nas fronteiras dos objetos

Em suma, “(...) o termo segmentação é usado como o sumário de todos os processos que constroem, modificam, crescem, agregam, cortam, encolhem, editam objetos” (Baatz *et al.*, 2008).

5.4.3. Classificação de imagens

Na análise de imagens baseada em objeto, o *image objet*⁵ é o elemento metodológico central (Lang, 2008), porque é após este processo de segmentação que a classificação pode ser iniciada.

A cada objeto é associado um Nível de Intensidade (NI) que corresponde à média dos Níveis Radiométricos (NR)⁶ dos elementos de imagem (píxeis ou objetos) que lhe deram origem. O facto de se passar a dispor de objetos (aglomerados de elementos de imagem), e não dos elementos de imagem individuais (píxeis), permite obter algumas bandas sintéticas com base nos valores de NI, as quais não seria possível de calcular numa análise baseada em píxeis. Como exemplos de bandas sintéticas numa análise orientada por objeto e por píxel, respetivamente, pode-se referir “(...) o brilho, que é a média dos NI daquele objeto em todas as bandas e o desvio padrão dos NR dos elementos de imagem que deram origem ao objeto” (Fonseca e Fernandes, 2004). Porém, é na vectorização dos objetos da imagem, que é possível retirar a informação topológica e todo o conhecimento sobre a forma dos elementos. Neste caso é possível construir bandas sintéticas em que “os NI associados a cada objeto vão ser, por exemplo: a área de cada objeto, o comprimento da fronteira do objeto, etc.” (Fonseca e Fernandes, 2004). Adicionalmente a toda esta informação que é possível retirar dos objetos, pode-se calcular com recurso ao eCognition® quaisquer outras bandas sintéticas que se afigurem úteis.

Independentemente da informação inerente aos objetos, estes podem ser criados com dimensões diferentes e em diversos níveis a partir da mesma imagem. Através da segmentação de uma imagem, o nível de detalhe e complexidade são reduzidos, tornando o conteúdo mais perceptível (Lang, 2008). Porém, o processo de segmentação de imagens é considerado como uma tarefa de nível baixo no contexto da análise de imagens, na medida em que as tarefas complementares e de nível alto são o

⁵ A imagem objeto corresponde ao conjunto de objetos construídos depois de se realizar a segmentação de uma imagem (Trimble, 2012)

⁶ O nível radiométrico (também designado por número digital - ND) corresponde à média da radiância registada pelo sensor para cada píxel da imagem (Lillesand *et al.*, 2003).

reconhecimento de objetos ou a classificação da imagem baseada em objetos. (Soille 2000; Marr 1982 em Radoux e Defourny, 2008)

Depois de segmentadas as imagens e criados os objetos, estes são classificados através de uma regra definida, cuja automatização se pode tornar difícil de concretizar (Marpu *et al.*, 2008). Procura-se que o processo de classificação automática seja preparado de forma a minimizar o envolvimento do Homem, mas a qualidade da classificação é fortemente dependente das segmentações produzidas, na medida em que será necessário “(...) que os objetos criados estejam bem-adaptados à estrutura dos objetos reais” (Gonçalves, 2002 em Encarnação, 2004). Por sua vez, no processo de segmentação a definição dos parâmetros é dependente da interpretação (quase sempre visual) do utilizador.

Independentemente do método utilizado, Lillesand *et al.* (2003) sugerem duas condições a considerar antes da classificação da imagem:

- i. A definição do sistema de classificação, onde, perante as classes de uso a encontrar, se definem os objetos que constituem determinada classe;
- ii. A definição da entidade mínima de análise, *i.e.*, objeto mais pequeno, decorrente do sistema de classificação e que determinará o nível de detalhe a considerar na classificação.

Além dos aspetos mencionados anteriormente, é fulcral ter em atenção a quantidade de dados que se quer trabalhar e qual a sua relação e dinâmicas. Quando as imagens adquiridas são multitemporais, como é o caso da presente dissertação, a segmentação pode ser feita de três formas diferentes, dependendo dos dados de entrada (Niemeyer *et al.*, 2008) (Figura 5.6):

- a) Com base no conjunto de dados bitemporais, ou seja, utilizando uma pilha⁷ de dados que consiste nas duas cenas;
- b) Com base nos dados de uma imagem referente a uma determinada data de aquisição os limites do objeto gerado são atribuídos aos dados das outras imagens sem segmentação;

⁷ Em ciência da computação, uma pilha (*stack* em) é um tipo abstracto de dados e de estrutura de dados, baseado no princípio de *Last In First Out* (LIFO).

a) Separadamente, são segmentadas todas as imagens de aquisições temporais diferentes.

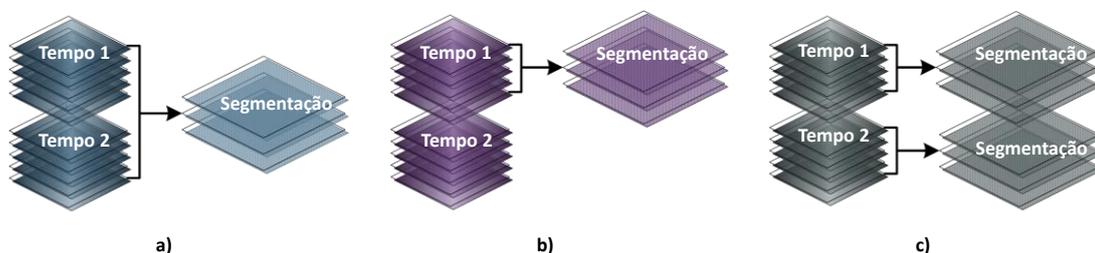


Figura 5.6 - Extração de objetos em dados de imagem adquirida em dois tempos diferentes

Quando se utiliza a segmentação sugerida nas hipóteses (a) e (b), os objetos produzidos têm as mesmas propriedades geométricas nas diferentes datas. Mesmo aplicando os mesmos parâmetros de segmentação em ambas as imagens dificilmente se obtêm objetos similares. Apenas no caso de as imagens serem idênticas, os resultados da segmentação poderá ser o mesmo. No entanto, no que diz respeito à detecção de alterações, os objetos de imagem têm os valores dos atributos, onde a forma e tamanho podem ou não variar com o tempo. No caso (c) as segmentações são independentes, conseqüentemente, a geometria dos objetos da imagem irão variar no tempo. Neste caso todos os objetos serão válidos para utilização na detecção de alterações.

Em suma, requer-se que numa análise baseada em objeto, a verificação de alterações apresente uma técnica de segmentação similar na extração dos objetos, onde não deve haver alterações significativas na sua forma e tamanho entre as várias aquisições. Isto porque a variação das características de forma dos objetos é um indicador importante na detecção de mudanças na ocupação do solo em termos gerais e em particular na área de estudo escolhida para o desenvolvimento desta dissertação (cf. secção 6).

Capítulo 6 - Material e Métodos

Neste capítulo é apresentada a área de estudo na qual são realizadas as classificações de cartografia de ocupação do solo. Esta é enquadrada administrativamente e caracterizada sucintamente ao nível da ocupação do solo.

São também descritos os métodos e dados necessários para a concretização do objetivo em estudo nesta dissertação. No que diz respeito aos dados, foram essencialmente utilizadas imagens do satélite Landsat 8. Porém, foram necessários diversos programas informáticos (*software*) para o desenvolvimento metodológico.

6.1. Enquadramento da unidade de análise

Na delimitação da área de estudo foram tidas em conta a diversidade e o dinamismo da ocupação do solo. Assim, com o auxílio do *CORINE Land Cover*, procurou-se uma imagem Landsat 8 que incluísse o maior número de classes e variação de ocupação do solo ao longo do tempo. Devido à média resolução espacial das imagens multiespectrais, são poucas as classes que se conseguem identificar, levando então à necessidade de se selecionar uma área de estudo (Figura 6.1) diversificada e com uma representação significativa de várias classes do CLC.

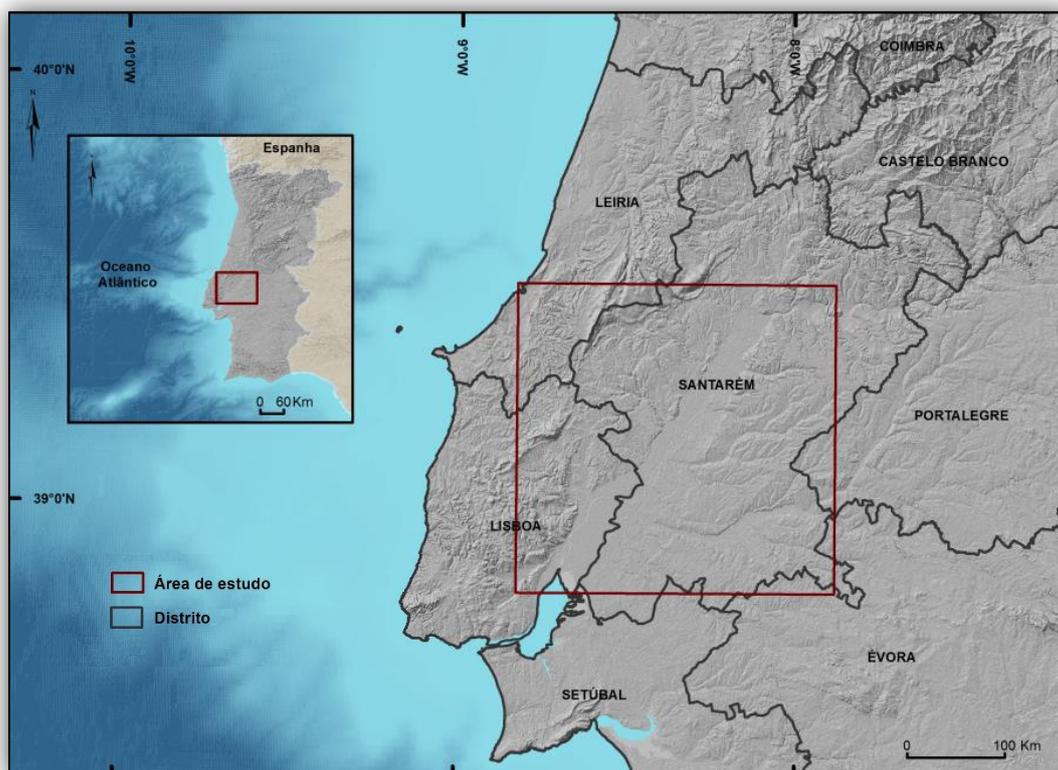


Figura 6.1 - Enquadramento da imagem Landsat 8 e respetiva área de estudo

Escolhida a localização, procedeu-se à redução da mesma de forma a diminuir a redundância de elementos de ocupação do solo existente. Na Tabela 6.1 e Figura 6.2 é possível localizar e posicionar as imagens Landsat 8 recolhidas, bem como a delimitação da área de estudo.

Tabela 6.1 Posicionamento e sistema de coordenadas das imagens Landsat8 recolhidas e da área de estudo

		Imagem completa	Imagem cortada
Posicionamento	Latitude	NW = 39°57'37,383"	NW = 39°52'52,08"
		SE = 37°50'6,26"	SE = 38°80'26,22"
	Longitude	NW = 10°12'58,191"	NW = 9°15'69,86"
		SE = 7°33'29,532"	SE = 8°21'01,06"
N.º colunas	7700	2713	
Nº linhas	7871	2673	
Projeção e elipsoide		UTM WGS84	
Zona		29 N	

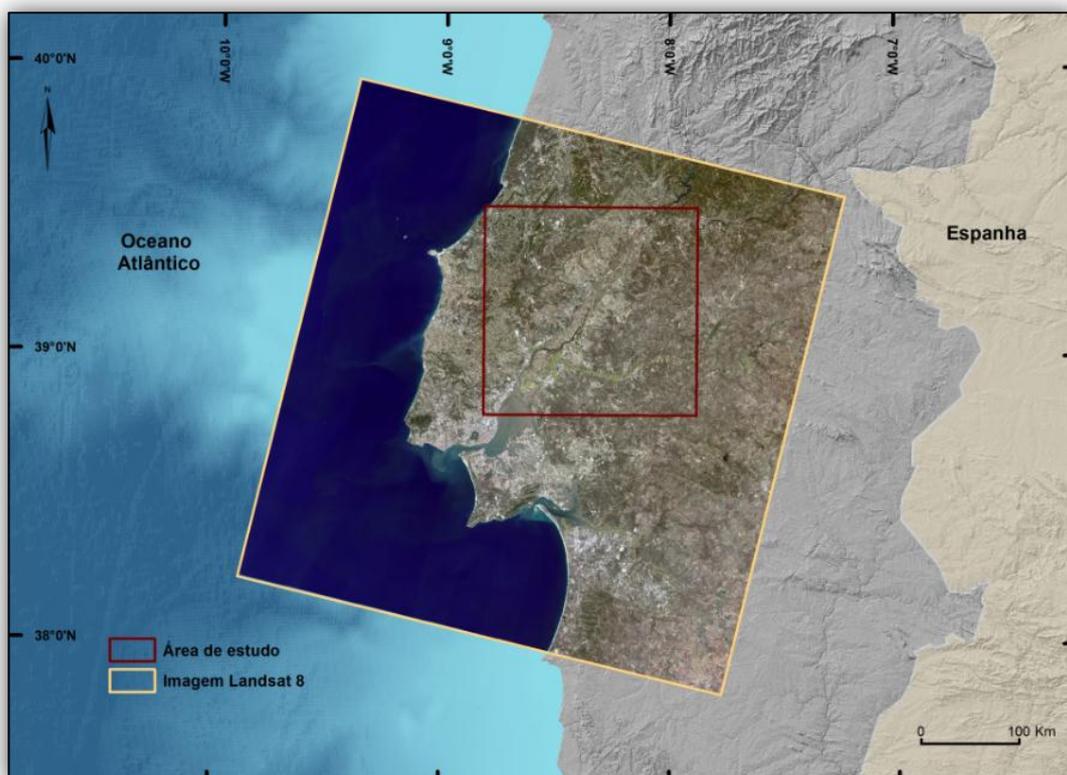


Figura 6.2 - Enquadramento geográfico da área de estudo

A área de estudo compreende aproximadamente 7312km² e a sua extensão é de 90,3km por 81km. Em termos administrativos abrange os distritos de Leiria, Lisboa, Santarém, Setúbal, Évora e Portalegre e cerca de 41 municípios.

6.2. Caracterização da ocupação do solo

No que diz respeito à ocupação do solo da área de estudo, foi elaborada uma análise do CLC de 2006 de forma a identificar os principais elementos que a compõem. Na Figura 6.3 é possível ver a representação cartográfica do nível 2 ao CLC para a área de estudo.

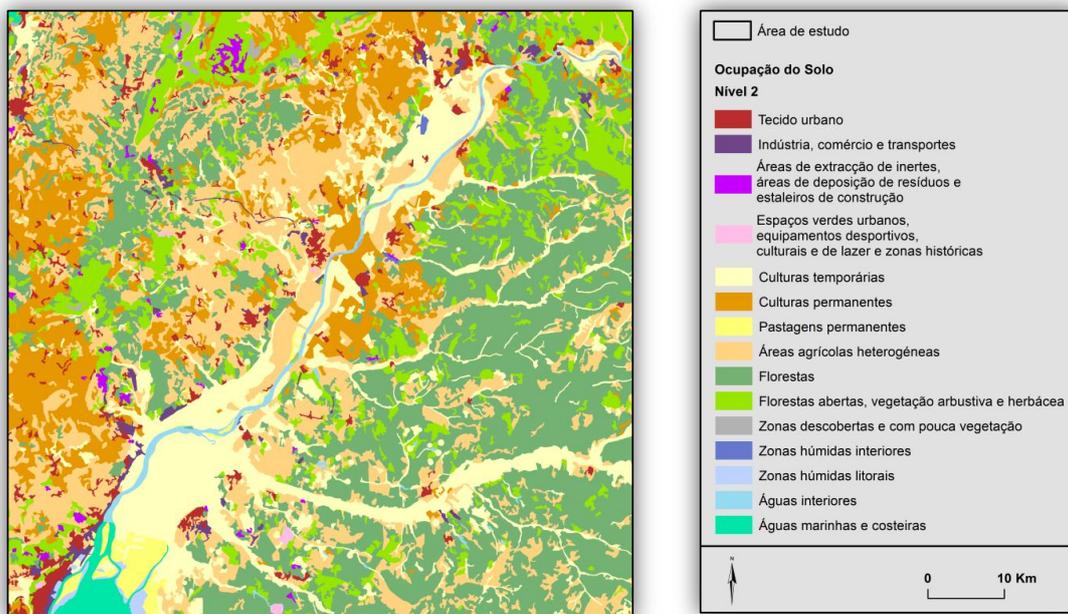


Figura 6.3 - Ocupação do solo da área de estudo no nível 2 do CLC de 2006

Posteriormente, com o intuito de se obter uma análise mais quantitativa, foram calculadas as áreas e respetiva percentagem de cada uma das classes nos níveis 1 e 2 da nomenclatura. Desta forma como é possível verificar na Tabela 6.2, existem dois grandes grupos no nível 1 que ocupam a quase totalidade da área. Primeiramente, abrangendo mais de metade da área de estudo, encontram-se as ‘áreas agrícolas e agroflorestais’ com um total de 51,58%. Em segundo, encontram-se as ‘florestas e meios naturais e seminaturais’ com um total de 41,97% de área ocupada. Em pormenor, observando ao nível 2, a predominância das as ‘áreas agrícolas e agroflorestais’ deve-se às áreas ‘agrícolas heterogéneas’ (23,82%), às ‘culturas temporárias’ (14,1%) e às ‘culturas permanentes’ (12,73%). Por outro lado, as ‘florestas e meios naturais e seminaturais’, são maioritariamente compostas por ‘floresta’ que ocupam 31,01 % da área. Em contraste, no nível 2 são as ‘zonas húmidas interiores’ (0,06%), os ‘espaços verdes urbanos, equipamentos desportivos, culturais e de lazer’ e as ‘zonas históricas’ (0,12%) as que possuem uma menor área de ocupação.

Tabela 6.2 - Área de ocupação do solo na área de estudo nos níveis 1 e 2 da nomenclatura do CLC de 2006

Nomenclatura <i>CORINE Land Cover</i>		Área de ocupação	
Nível 1	Nível 2	%	Km ²
1 Territórios artificializados	1.1 Tecido urbano	2,77	181
	1.2 Indústria, comércio e transportes	0,92	60
	1.3 Áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção	0,51	33
	1.4 Espaços verdes urbanos, equipamentos desportivos, culturais e de lazer e zonas históricas	0,12	8
2 Áreas agrícolas e agroflorestais	2.1 Culturas temporárias	14,10	920
	2.2 Culturas permanentes	12,73	831
	2.3 Pastagens permanentes	0,93	61
	2.4 Áreas agrícolas heterogéneas	23,82	1555
3 Florestas e meios naturais e seminaturais	3.1 Florestas	31,10	2030
	3.2 Florestas abertas, vegetação arbustiva e herbácea	10,59	691
	3.3 Zonas descobertas e com pouca vegetação	0,28	18
4 Zonas húmidas	4.1 Zonas húmidas interiores	0,06	4
	4.2 Zonas húmidas litorais	0,29	19
5 Corpos de água	5.1 Águas interiores	0,78	51
	5.2 Águas marinhas e costeiras	1,01	66

Em suma, pode-se concluir que a área de estudo é ocupada maioritariamente por áreas agrícolas e florestas, sendo pouco artificializada e possuindo áreas reduzidas de zonas húmidas (0,35%) e corpos de água (1,79%).

6.3. Imagens de satélite Landsat

Na década de 1960, a ideia de utilizar dados provenientes de satélites para a monitorização e mapeamento da superfície terrestre, era um ideal visionário. Porém, a 20 de setembro de 1966 numa conferência em Washington, várias individualidades, nomeadamente, William Pecora, director do *United States Geological Survey* (USGS) e Stewart Udall, secretário do Departamento do Interior do Governo dos Estados Unidos (DOI), anunciaram os planos referentes à criação do programa *Earth Resources Observation Satellites* (EROS). Este programa nasce da valorização existente nos primeiros satélites, meteorológicos e das potencialidades que as fotografias orbitais das missões Gemini e Mercúrio demonstraram ter no estudo dos recursos terrestres. Desta

forma, visava-se a criação de um conjunto de satélites de deteção remota capazes de reunir dados sobre os recursos naturais e superfície terrestre.

Em 1967 uma nova geração de satélites designados de *Earth Resources Technology Satellites* (ERTS) vieram revolucionar as capacidades de deteção remota existentes até á data. A *National Aeronautics and Space Administration* (NASA) com a colaboração do DOI, em 1970 deu início à construção do primeiro satélite, ETRS1 lançado dois anos depois.

O enorme sucesso da informação obtida através deste satélite levou à criação de novos satélites, onde foram sendo incorporadas novas funcionalidades e características, em especial nos sensores. Antes do lançamento do terceiro satélite, a NASA atribuiu uma nova denominação aos satélites ETRS, de forma a não serem confundidos com o satélite *Sea Surveillance Satellite* (Seasat), sendo renomeados de Landsat.

Em 1982 a operacionalidade dos satélites Landsat foi transferida para a *United States National Oceanographic and Atmospheric Administration* (NOOA), entrando-se num processo de privatização. Mais tarde, em 1986 o programa passou a ser gerido pela *Earth Observation Satellite Company* (EOSAT), uma organização comercial civil cujo objetivo, ao contrário da NASA, era o de obter lucros com as imagens obtidas através dos seus satélites.

A restrição ao acesso de informação proveniente dos satélites Landsat, levou a que em 1992 no Congresso dos Estados Unidos, o presidente Bush aprovasse legislação que visava a devolução da operacionalidade do Landsat ao domínio público. Por conseguinte, em 1994 o Landsat retornou à NASA através do programa *Mission to Planet Earth*, iniciando-se com o lançamento do Landsat 7 em conjunto com a NOAA e o *United States Geological Survey's EROS Data Center* (EDC). No entanto, após o lançamento deste satélite (Landsat 7), a operacionalidade do programa Landsat foi novamente abandonado pela NASA, sendo transferida para o EDC.

Aproximadamente uma década depois do lançamento do Landsat 7, eis que aparece o *Landsat Data Continuity Mission* (LDCM). Este novo satélite surge da cooperação entre a NASA e a USGS, a primeira ficou responsável pela construção e

lançamento, enquanto a USGS liderava o desenvolvimento do sistema de aterragem. Posteriormente, a 30 de maio de 2013 a USGS assumiu a responsabilidade das operações do satélite e da recolha e arquivo dos dados, renomeando o satélite para Landsat 8.

O principal objetivo do Landsat 8 prende-se com a recolha de dados suficientemente consistentes com os dos satélites antecedentes, de forma a permitir estudos de uso e ocupação do solo numa escala multitemporal. A consistência da informação diz respeito à geometria, calibração, características de cobertura espectrais e espaciais, qualidade dos produtos de saída e disponibilidade dos dados. Desta forma, é possível à comunidade (científica, civil, etc.) comparar dados do satélite numa base mensal. O Landsat 8 pretende respeitar as características dos satélites anteriores ao recolher dados de imagem multiespectral digitais da cobertura da superfície terrestre.

Na Tabela6.3 encontram-se especificadas as principais características referentes aos satélites do programa Landsat. Como se pode verificar, o Landsat 8 foi o último satélite a ser lançado e com este, passou a ser recolhido um novo leque de informação.

A integração de dois novos sensores, *Operational Land Imager (OLI)* e *Thermal Infrared Sensor (TIRS)*, permitiu a obtenção de novos dados (Tabela 6.4). O sensor OLI face aos anteriores (ETM e ETM+), apresenta duas novas bandas espectrais – uma adaptada especialmente para detetar nuvens e outra para a observação de áreas costeiras. O TIRS tem a capacidade de medir a energia térmica emitida pelos corpos/objetos.

Tabela 6.4 - Principais características dos sensores OLI e TIRS do satélite Landsat 8

Características técnicas do sensor OLI			
Resolução radiométrica	16 <i>bits</i> por píxel*		
Resolução espacial	Multiespectral: 30 metros Pancromática: 15 metros		
Precisão de localização	12 metros		
Tamanho da faixa	185,0 x 185,0 km		
* resolução de 12 <i>bits</i> no momento da aquisição (produto L0) e posteriormente reamostrada para 16 <i>bits</i> depois da correção radiométrica e georreferenciação (produto L1)			
	Bandas	Zonas do espectro eletromagnético	Intervalo de comprimentos de onda (µm)
	1	Costal	0,435 – 0,451
	2	Azul	0,452 – 0,512
	3	Verde	0,533 – 0,590
	4	Vermelho	0,636 – 0,673
Resolução espectral	5	IV próximo	0,851 – 0,879
	6	IV de comprimento de onda curto 1	1,566 – 1,651
	7	IV de comprimento de onda curto 2	2,107 – 2,294
	8	Pancromática	0,503 – 0,676
	9	Nuvens	1,363 – 1,384
Características técnicas do sensor TIRS			
Resolução radiométrica	16 <i>bits</i> por píxel		
Resolução espacial	Térmica: 100 metros		
Precisão de localização	41 metros		
Tamanho da faixa	185,0 x 185,0 km		
	Bandas	Zonas do espectro eletromagnético	Intervalo de comprimentos de onda (µm)
Resolução espectral	10	IV térmico 1	10.60 – 11.19
	11	IV térmico 2	11.50 – 12.51

Anteriormente (Landsat 4 a 7), a informação térmica era apenas coberta por uma banda espectral mais larga enquanto no Landsat 8 os dados são recolhidos através

de duas bandas espectrais, constituindo um ganho na resolução espectral, mas infelizmente com perda de resolução espacial que passou dos anteriores 30 metros para 100 metros. Esta decisão foi bastante polémica e tem sido alvo de críticas pois além de haver uma perda de qualidade espacial a nova informação é difícil de compatibilizar com a anterior. Efetivamente, os 30 metros (Landsat 7) e os 60 metros (Landsat 4 e 5), eram compatíveis, *i.e.*, múltiplos, das restantes bandas multiespectrais (30 metros) e pancromática (15 metros), enquanto isso já não verifica com os atuais 100 metros. O LDCM também consegue captar cerca de 400 cenas por dia (mais 150 que no Landsat 7), contribuindo para uma maior extensão do arquivo de dados do USGS, e consequentemente o aumento da qualidade das imagens, uma vez que a probabilidade de capturar imagens sem nuvens é maior. A Figura 6.4 compara o enquadramento dos diversos sensores do programa Landsat no espectro eletromagnético.

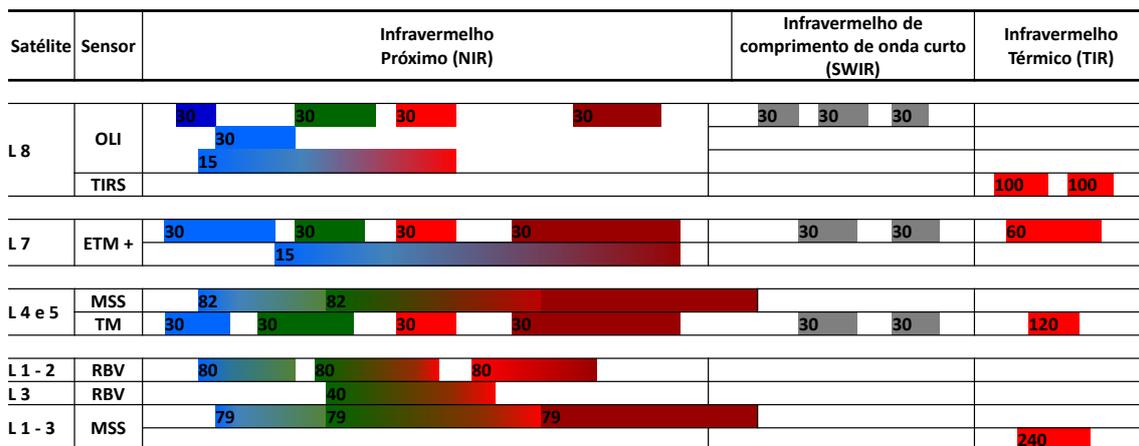


Figura 6.4 - Comparação do espectro eletromagnético entre o Landsat 1 e Landsat 8 (adaptado de USGS 2015)

A recolha das imagens para esta dissertação foi feita através do *USGS EarthExplorer*, uma base de dados que permite a pesquisa e recolha, não só de imagens de satélite, como de fotografias aéreas e, outros produtos cartográficos de diversas fontes.

Devido à existência recente deste satélite, os dados apresentam uma amplitude temporal reduzida, contribuindo para uma limitação da informação disponível. Em

conjunto com este facto, a maioria das imagens captadas apresentam uma elevada cobertura de nuvens, o que acrescido da sombra das mesmas, compromete uma boa classificação e não permite obter informação relativa à ocupação do solo nas áreas afetadas. Desta forma, apenas foram consideradas imagens com valores de área coberta por nuvens inferiores a 5%.

Num total de 40 imagens disponíveis, apenas foram recolhidas 10 (cobertura de nuvens inferior a 5%), das quais só 8 foram utilizadas em consequência de problemas técnicos nas bandas térmicas das imagens referentes ao ano de 2015 (Tabela 6.5 e Figura 6.5).

Tabela 6.5 - Datação das imagens Landsat 8 selecionadas

Imagens Landsat 8 selecionadas					
	Dia	Mês	Ano	Identificador	% Nuvens
a)	22	julho	2013	LC82040332013203LGN00	0,99
b)	23	agosto	2013	LC82040332013235LGN00	4,61
c)	08	setembro	2013	LC82040332013251LGN00	0,10
d)	10	outubro	2013	LC82040332013283LGN00	0,14
e)	11	novembro	2013	LC82040332013315LGN00	4,80
f)	27	novembro	2013	LC82040332013331LGN00	1,66
g)	09	julho	2014	LC82040332014190LGN00	0,11
h)	29	outubro	2014	LC82040332014302LGN00	0,40

A escolha de dados orbitais de média/alta resolução, prende-se com o facto de nesta dissertação o objetivo principal ser o de aplicar uma abordagem de classificação baseada em objeto, de forma (semi)automática, para ser aplicado a outras imagens da mesma área geográfica, mas adquiridas noutras épocas. O ideal será o uso de imagens de média resolução ao invés de imagens de alta resolução espacial, onde o processo de classificação seria temporalmente mais extenso, pormenorizado e os custos de recolha dos dados seriam maiores, uma vez que os mesmos não são gratuitos ao contrário do verificado com as imagens Landsat 8. Deste modo assegura-se um processo de produção de cartografia de ocupação do solo, célere e pouco oneroso, possibilitando a obtenção de informação extremamente importante para os processos de elaboração e/ou validação das ações de planeamento e ordenamento do território.



a)



b)



c)



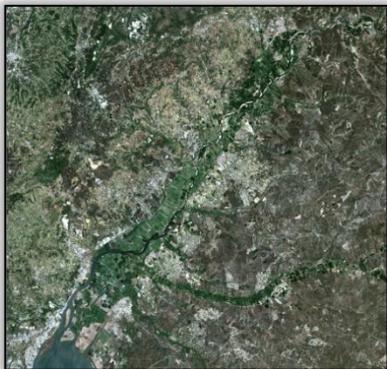
d)



e)



f)



g)



h)

Figura 6.5 - Imagens Landsat 8 selecionadas

6.4. Programas informáticos

O *software* denominado eCognition® foi apresentado em várias conferências em 1999 e 2000, tendo-se tornado depois disponível (a partir de 2000) como o primeiro *software* comercial disponível para análise de imagens com base em objetos (Flanders *et al.*, 2003; Benz *et al.*, 2004). Este *software* foi construído sobre a abordagem, originalmente conhecida como *Fractal Net Evolution* (Baatz e Schäpe, 2000) e desenvolvido em fluxos de trabalho completamente programáveis (Baatz *et al.*, 2008): hoje é um produto de uma empresa de Munique denominada Definiens (Lang e Tiede, 2007), a qual foi fundada pelo prémio Nobel Binning de Gerd. Este *software* de análise de imagem baseada em objetos é, em princípio, adequado para uso em todos os campos da deteção remota. O eCognition® tem sido continuamente desenvolvido desde o seu aparecimento em 1999 com a intenção de que todos os pontos fracos pudessem ser detetados e posteriormente corrigidos, contribuindo para uma melhoria do *software*.

O sucesso do eCognition® desencadeou o desenvolvimento de outros programas informáticos como o *Feature Analyst* (Opitz e Blundell, 2008), o *System for Automated Geoscientific Analyses* (SAGA) (Böhner *et al.*, 2006) e, mais recentemente, o *ENVI Feature Extraction* (Hölbling e Neubert, 2008) ou o *Erdas Imagine*. Um segundo grande grupo mas muito heterogéneo em termos de procedimentos de segmentação é e sempre foi, o dos algoritmos isolados ou pacotes avulsos de *software* desenvolvidos em ambiente académico, alguns deles de distribuição livre (*freeware*)⁸ ou de código aberto (*open source*)⁹. Por exemplo, Wuest e Zhang (2009), utilizaram o quadro de segmentação introduzido por Ojala e Pietikäinen (1999), designado de divisão e fusão hierárquica refinada (*Hierarchical Split Merge Refinement* [HSMR]) ao qual também

⁸ Os utilizadores têm liberdade para distribuir o *software*, *i.e.*, a licença não deve restringir de nenhuma forma a distribuição gratuita do programa, como componente de outro programa ou não. Não confundir com o termo, mais abrangente, "*software* livre" (*free software*) que pressupõe que os utilizadores têm a liberdade de executar, copiar, distribuir, estudar, mudar e melhorar o *software*. Assim, o "*software* livre" é uma questão de liberdade, não de preço. Todo o *software* livre é de livre distribuição, mas o inverso pode não se verificar.

⁹ Geralmente, o termo código aberto refere-se a um programa de computador em que o código fonte está disponível ao público em geral para uso e/ou modificação de seu *design* original. Destina-se a ser um esforço colaborativo, onde os programadores aperfeiçoam o código-fonte e compartilham as mudanças no seio da comunidade de utilizadores. Um programa de código aberto deve ser de distribuição livre.

recorreram no campo da detecção remota. Existem também várias aplicações com base no trabalho desenvolvido na NASA por Tilton (Tilton, 1998), também este um algoritmo hierárquico de divisão e fusão e que mais tarde foi transformado num *software* funcional, não-comercial (Neubert *et al.*, 2008).

Contudo, deve-se referir claramente que a maioria dos trabalhos baseados em OBIA se centra no eCognition® (Baatz e Schäpe, 2000; Flanders *et al.*, 2003; Benz *et al.*, 2004), o que acaba por justificar a sua escolha para servir de suporte à elaboração da presente dissertação.

Assim, dado que todas as análises baseadas em objetos realizadas no âmbito desta dissertação foram realizadas com eCognition®, os princípios básicos, os modos de operação e os algoritmos deste *software* têm sido, e continuarão a ser, descritos e derivados em detalhe ao longo do texto. Nesta dissertação, o eCognition® é usado no contexto da classificação multitemporal reproduzível de imagens baseada em objeto recorrendo a imagens de satélite de média-alta resolução

O eCognition® é o único *software* comercial de análise baseada em objetos desenvolvido especialmente para o campo da análise de imagens. Este *software* oferece um novo potencial e preenche critérios decisivos, incluindo importantes aspetos multifonte, multimétodo e multi-escala. Além disso, o eCognition® caracteriza-se pelos poderosos algoritmos de segmentação de que dispõe atualmente e a possibilidade de modelação e classificação cruzadas e hierárquicas.

Uma desvantagem do eCognition® é a falta de capacidade para o pré-processamento necessário dos dados de detecção remota. Estas etapas de pré-processamento são indispensáveis. Isto implica que seja sempre necessário o recurso a programas adicionais de detecção remota e, portanto, é quase impossível trabalhar no campo da detecção remota só com eCognition®. Também deve ser mencionado que não há nenhuma possibilidade de reprodutibilidade independente, como já foi mencionada. Além disso, não há nenhuma ferramenta abrangente, estatística ou realmente satisfatória para o campo de extração de características. Por vezes é entediante e demorado filtrar os valores de limite que descrevem uma classe de objeto bem do grande número de possíveis características (predefinidas) e valores.

Assim, ao longo da dissertação, inúmeros programas informáticos foram utilizados. Uma breve descrição dos mesmos é apresentada na Tabela 6.6.

Tabela 6.6 - Software utilizado na execução do trabalho

<i>Software</i>	Detentor	Versão	Utilização
PCI Geomatica® 	PCI Geomatics	Geomatica 2010	Junção de bandas e delimitação da área de estudo
eCognition® 	Trimble Navigation	8	Classificação das imagens e construção do algoritmo
MatLab® 	MathWorks	R2013b	Execução das Análises por Componentes Principais
ArcMap® 	Esri	ArcGis 10.2	Tratamento dos dados de entrada para a matriz de confusão

6.5. Metodologia de análise

Ao longo do tempo tem sido realizada uma grande quantidade e diversidade de estudos de cartografia de ocupação do solo. Porém, “(...) não existe uma metodologia padrão para a produção automática ou semiautomática de cartografia com base em dados de satélite” (Caetano *et al.*, 2002 em Oliveira, 2011) com capacidade de transferência metodológica entre diferentes datas. Desta forma, esta dissertação pretende apresentar um novo método de classificação semiautomática capaz de produzir cartografia multitemporal. Para tal, optou-se por recorrer a uma metodologia (Figura 6.6) que possibilite desenvolver regras de decisão com capacidade de serem replicadas, e com resultados considerados satisfatórios para aplicação em planeamento e ordenamento do território.

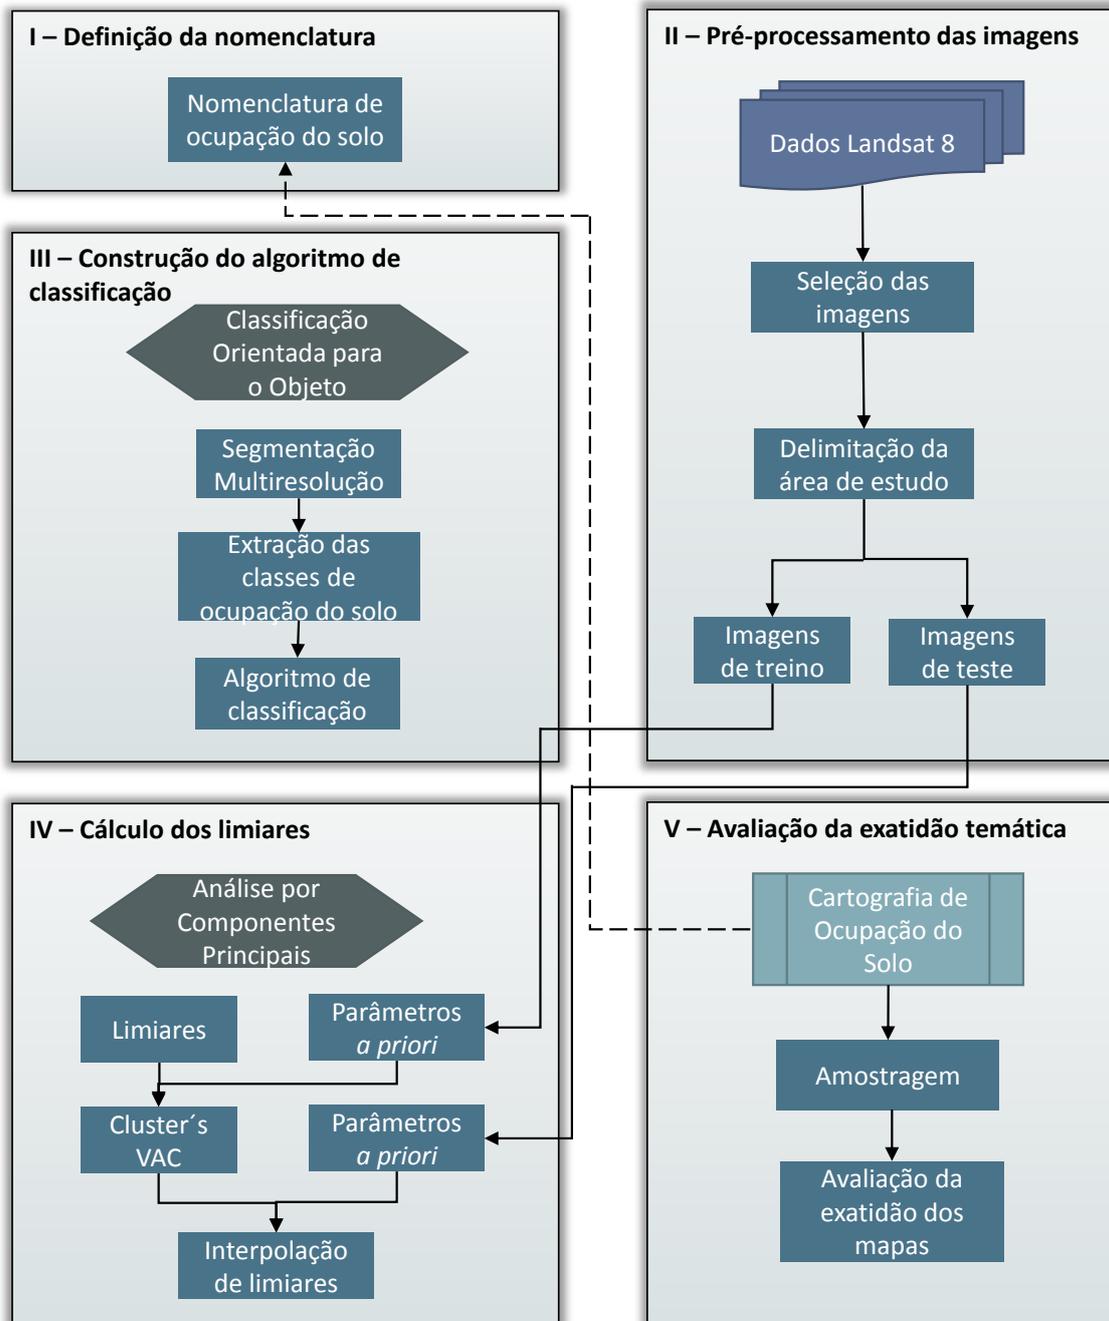


Figura 6.6 - Fluxograma geral da metodologia

Assim, para a concretização do objetivo proposto nesta dissertação, a metodologia realizada encontra-se estruturada em 3 processos nucleares:

- I. Construção do algoritmo de classificação baseado em objetos;
- II. Cálculo semiautomático de limiares para as funções de classificação, para diferentes épocas através da análise por componentes principais;
- III. Avaliação da exatidão temática.

No fluxograma da Figura 6.6 é possível visualizar a várias etapas deste trabalho. Além dos 3 processos metodológicos principais mencionados, necessitam de ser realizados outros dois passos, nomeadamente:

- IV. Definição da nomenclatura de ocupação do solo;
- V. Pré-processamento das imagens.

6.6. Definição da nomenclatura de ocupação do solo

Para analisar e produzir cartografia de ocupação do solo, é necessário estabelecer à partida uma nomenclatura que descreva os vários tipos de ocupação que se pretende analisar (*cf.* secção 2.1). A definição da nomenclatura deve ser “(...) ponderada em função dos objetivos da cartografia, das suas características técnicas, do método de produção e deverá respeitar critérios de coerência e clareza” (Costa, 2008).

A maioria das nomenclaturas usadas para cartografia ou estatísticas relacionadas com o espaço utiliza terminologias de uso do solo dirigidas para a compilação das atividades humanas. A construção de uma nomenclatura de uso e ocupação precisa de estar adequada para cartografar a diversidade do território considerado e deve ser compatível com a escala, o tamanho da UMC, a fonte de dados base e com as necessidades dos utilizadores. Para se garantir a reprodução de resultados de um intérprete para outro, a terminologia necessita ser clara e precisa, não podendo ter sentido vago ou ambíguo.

No que diz respeito a este estudo, optou-se pelo uso da nomenclatura *CORINE Land Cover* na definição inicial das classes, por ser a que mais se aproxima do objetivo pretendido (*cf.* secção 3). Os países membros da União Europeia têm uma produção cartográfica normalizada de dados de ocupação do solo de acordo com as especificações do projeto CLC. Nesta nomenclatura, hierárquica e estabelecida *a priori*, existiu uma tentativa de compatibilização entre as diferentes realidades da Europa, embora seja, por vezes, necessário incluir adaptações relativas à especificidade de cada contexto geográfico.

As classes foram definidas com o intuito de classificar o uso e ocupação do solo da União Europeia, através de imagens de satélite (Landsat e SPOT) a uma escala de 1:100 000. A nomenclatura é composta por 44 classes distribuídas em 3 níveis hierárquicos (*cf.* anexo).

Em relação à presente dissertação, foram extraídas 7 classes de ocupação do solo, subdividindo-se em 2 níveis hierárquicos de acordo com o CLC (a negrito na Tabela 6.7). De forma a existir uma correspondência fidedigna entre as classes extraídas e as do CLC, procedeu-se a uma análise da ocupação presente em cada classe e verificou-se qual a designação CLC correspondente. Neste processo de adaptação, foi tido em conta a resolução espacial e a capacidade de discriminação das imagens de modo a respeitar os pressupostos que estão na base da dissertação, *i.e.*, replicabilidade e qualidade.

Com o auxílio da nomenclatura completa (*cf.* anexo) é possível identificar com maior pormenor os elementos que compõem cada classe.

Tabela 6.7 - Designação das classes em estudo segundo a nomenclatura CLC 2006

Nível 1		Nível 2	
1	Territórios artificializados	1.1	Tecido Urbano
		1.2	Indústria, comércio e transportes
		1.3	Áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção
		1.4	Equipamentos desportivos, culturais e de lazer e zonas históricas
2	Áreas agrícolas e agroflorestais	2.1	Culturas temporárias
		2.2	Culturas permanentes
		2.3	Pastagens permanentes
		2.4	Áreas agrícolas heterogéneas
3	Florestas e meios naturais e seminaturais	3.1	Florestas
		3.2	Florestas abertas, vegetação arbustiva e herbácea
		3.3	Zonas descobertas e com pouca vegetação
4	Zonas húmidas	4.1	Zonas húmidas interiores
		4.2	Zonas húmidas litorais
5	Corpos de água	5.1	Águas interiores
		5.2	Águas marinhas e costeiras

Por fim, na Figura 6.7 encontram-se exemplificadas as classes selecionadas no contexto da dissertação.



1 - Territórios artificializados



2 - Áreas agrícolas e ago-florestais



3 - Florestas e meios naturais e seminaturais



3.3 - Zonas descobertas e com pouca vegetação



4.2 - Zonas húmidas litorais



5.1 - Águas interiores



5.2 - Águas marinhas e costeiras

Figura 6.7 - Exemplos de cada classe de ocupação do solo presente na área de estudo

Capítulo 7 - Aplicação do algoritmo de Classificação

A construção do algoritmo de classificação das imagens e a sua aplicação constituem o processo metodológico mais importante, o qual engloba a maioria das tarefas. Este processo influenciou a definição da nomenclatura de ocupação do solo, porque foi nesta fase que foi possível identificar quais as classes de ocupação do solo passíveis de ser extraídas e quais as melhores variáveis para a classificação das mesmas.

É de lembrar que um dos principais problemas na automatização ou semi-automatização dos processos de classificação da ocupação do solo usando OBIA, é a forma como extrair a informação necessária, face ao grande volume de informação que se encontra associado a cada objeto da imagem. Assim, a abordagem adequada para alcançar os objetivos pretendidos requer múltiplas valências: a “(...) extração de classes alvo, o uso de ferramentas espaciais e estruturais não só exige habilidades computacionais, mas também uma riqueza de conhecimentos sobre a área e a composição da imagem” (Lang, 2008).

Para um melhor entendimento dos passos seguidos, ir-se-á explicar em detalhe as etapas de construção do algoritmo que compõe a peça fundamental para o desenvolvimento da metodologia pretendida.

7.1. Algoritmo de segmentação

O processo de segmentação é a base para uma boa classificação. A criação de objetos a partir da imagem, permite alargar o leque de variáveis a utilizar para a extração de classes. Assim, deve ser realizada uma boa representação dos elementos de ocupação do solo através de objetos, para que a classificação seja facilitada e executável. Para gerar os objetos recorreu-se a um conhecimento *a priori* da área de estudo garantindo assim uma decisão mais assertiva, ou pelo menos mais informada, acerca da escala a utilizar e dos pesos a atribuir a cada critério.

Primeiramente, optou-se por extrair a classe de ocupação do solo com maior representatividade na área em estudo, a ‘vegetação’. Assim, os parâmetros da primeira

segmentação (Tabela 7.1) foram definidos com o intuito de se aproximarem o máximo possível dos elementos correspondentes à ‘vegetação’. Considerou-se um parâmetro de escala de 60 e deu-se mais importância ao critério de homogeneidade da cor, porque a vegetação é mais facilmente detetada pela cor do que pela sua forma, uma vez que esta apresenta uma ocupação bastante dispersa e/ou irregular. Por fim, foram atribuídos pesos mais elevados às bandas 4 e 5 (banda correspondente ao Vermelho (V) e Infravermelho Próximo (IVP), respetivamente), porque são comprimentos de onda que permitem uma maior sensibilidade na discriminação da vegetação.

Tabela 7.1 - Parâmetros adotados nas segmentações utilizadas para a classificação das imagens

Parâmetros		Segmentação 1	Segmentação 2	Segmentação 3
Nível		-	<i>Create below</i>	<i>Create above</i>
Peso das camadas de imagem		1, 2, 2, 6, 6, 3,	1, 1, 1, 1, 8, 8,	1, 2, 2, 6, 6, 3,
		7,8,9,10,11	2, 2, 0, 1, 2	1, 0, 0, 6, 1,
	Escala	60	20	60
Composição dos critérios de homogeneidade	Cor	0,9	0,9	0,9
	Forma	0,1	0,1	0,1
	Suavidade	0,5	0,9	0,5
	Compacidade	0,5	0,1	0,5

De seguida, houve a necessidade de efetuar uma nova segmentação (a segunda) para a extração das áreas referentes aos ‘corpos de água’. Esta classe apresenta uma dificuldade de extração acrescida devido à resolução espacial da imagem. A maioria dos corpos de água ocupa apenas alguns píxeis, dos quais uma parte considerável representa uma mistura da resposta espectral da classe ‘corpos de água’ com a resposta espectral das classes circundantes, *i.e.*, são píxeis não-puros ou de mistura sendo conhecidos por míxeis (do Inglês *mixels*).

A segunda segmentação foi criada num nível abaixo da anterior, *i.e.*, através da divisão dos objetos já existentes, uma vez que apresenta um parâmetro de escala menor, mais precisamente de 20. Sendo o objetivo extrair os corpos de água, foram atribuídos pesos mais elevados às bandas 5 e 6 (banda correspondente ao Infravermelho Próximo (IVP) e Infravermelho de comprimento de onda curto (IVOC1), respetivamente), porque os corpos de água apresentam uma elevada reflectância nestes comprimentos de onda. A banda 10 (Infravermelho térmico 1) também foi

importante para a criação dos objetos, porque ajudou na distinção entre os corpos de água e os restantes elementos de ocupação do solo. Por fim, atribuíram-se valores maiores aos critérios de homogeneidade relativos à cor e à suavidade, porque são os que melhor representam o comportamento desta classe.

Para a extração das restantes classes (segmentação 3), optou-se por voltar a utilizar os parâmetros da segmentação inicial, na medida em que esta era a que apresenta a escala e os critérios que melhor segmentam a imagem.

Por fim, nas várias segmentações realizadas, os restantes pesos e critérios que não foram mencionados anteriormente, foram definidos através de várias tentativas de forma a segmentarem a imagem da melhor forma e apenas foram necessárias pequenas adaptações para satisfazer os resultados pretendidos.

7.2. Variáveis utilizadas e identificação de limiares

Para a classificação da ocupação do solo recorrendo a OBIA é necessário proceder a pré-análise das imagens, de forma a conhecer o território e os elementos nele presentes. Muitas vezes bandas de diferentes comprimentos de onda apresentam a mesma informação, *i.e.*, respostas espectrais idênticas. Assim, pretende-se que as variáveis reunidas descrevam da melhor forma a resposta espectral de cada classe de ocupação do solo a extrair da imagem. Na Tabela 7.2 pretende-se discriminar de uma forma geral, qual a utilidade de cada banda na extração das classes.

Tabela 7.2 - Discriminação da aplicação das bandas Landsat 8

Canal e Intervalo de comprimentos de onda (μm)		Aplicação
Banda 1	0,435 – 0,451	Utilizada para estudos da superfície da água e caracterização da hidrologia costeira.
Banda 2	0,452 – 0,512	Mapeamento batimétrico, distinção do solo da vegetação e vegetação conífera
Banda 3	0,533 – 0,590	Apresenta uma grande sensibilidade na presença de sedimentos em suspensão, possibilitando a sua análise em termos de quantidade e qualidade. Fornece informação relativa ao estado da vegetação, porque permite observar a reflectância da vegetação verde e vigorosa. Também é útil para a identificação de culturas.
Banda 4	0,636 – 0,673	Penetração limitada da água; reflete bem a partir da folhagem morta; útil para identificação de tipos de vegetação, solos e características urbanas, pois apresenta um bom contraste. Permite a análise da variação litológica em áreas com pouca cobertura vegetal.
Banda 5	0,851 – 0,879	Enfatiza a biomassa e linhas costeiras. Muito boa para diferenciar solo/agricultura e água/solo e na validação do teor de humidade do solo.
Banda 6	1,566 – 1,651	Discrimina o conteúdo de humidade do solo e da vegetação, permitindo observar o <i>stress</i> hídrico; penetra nuvens finas, discriminando nuvens, neve e gelo.
Banda 7	2,107 – 2,294	Apresenta sensibilidade à morfologia do terreno, permitindo obter informações sobre geomorfologia, solos e geologia. Permite a discriminação de tipos de rochas e solo, e também para estudar a humidade na vegetação e solo.
Banda 8	0,503 – 0,676	Imagens a branco e preto melhoram a nitidez das imagens
Banda 9	1,363 – 1,384	Deteção das nuvens e sua contaminação
Banda 10	10,60 – 11,19	Mapeamento termal, apresentando sensibilidade nas rochas, solos, vegetação e água. Útil na estimação da humidade do solo, na localização de fontes de calor em meio urbano e na determinação dos níveis de poluição na atmosfera.
Banda 11	11,50 – 12,51	

7.2.1. Transformação de bandas

A seleção de variáveis é uma etapa bastante importante para uma classificação bem-sucedida. Em muitos estudos, a maioria da extração da informação é realizada com recurso à transformação de bandas (Caetano *et al.*, 2002). O objetivo da criação destas novas variáveis passa por diminuir a redundância de informação nos dados e/ou por extrair informação específica de ocupação do solo (Lu e Weng, 2007). No âmbito desta dissertação, existiu a necessidade de recorrer a cinco variáveis:

a) Normalized Difference Vegetation Index (NDVI)

Desenvolvido por Rouse *et al.*, (1973) e referido por Jensen (2004), o índice de diferença normalizada da vegetação (*NDVI*) é o índice de vegetação mais utilizado para estimar a abundância e/ou o vigor da vegetação numa dada área. Resulta da combinação matemática de duas bandas, a correspondente ao Infravermelho Próximo (*IVP*) e a correspondente ao Vermelho (*V*), e é calculado por:

$$NDVI = \frac{IVP - V}{IVP + V} . \quad (7.1)$$

O comportamento espectral da vegetação não se pode generalizar. Existem vários fatores que influenciam a sua resposta, como por exemplo a espécie vegetal, mesmo dentro de uma mesma espécie existem fatores que moldam uma curva espectral específica.

A utilização do NDVI prende-se com o facto de apresentar uma “(...) forte correlação positiva com a acumulação de biomassa, com atividade clorofilina, com o índice de área foliar e com a atividade fotossintética” (Oliveira, 2011), permitindo o realce da vegetação, em contraste com os outros elementos de ocupação do solo presentes na imagem.

Sabendo-se que esta estrutura interna das folhas varia consoante as espécies, pode-se afirmar que a banda do infravermelho próximo é útil no processo de discriminação dos diferentes tipos de vegetação, através das condições da reflectância. Para além disso, o contraste de reflectância vegetal, entre o visível (especialmente no vermelho 0,636µm a 0,673µm) e o infravermelho próximo (0,581µm a 0,879µm) permite concluir que será tanto maior o vigor de uma espécie, quanto maior for o contraste entre estas duas bandas. Em conjunto, estas duas bandas têm a aptidão de aferir diferentes profundidades de vegetação, o IVP pode percepcionar cerca de oito camadas de folhas, enquanto o V apenas uma camada ou menos (Lillesaeter, 1982 em Gao, 1996).

Por se tratar de um índice normalizado, os valores variam ente -1 e 1. As áreas com vegetação apresentam os valores do índice mais elevados, enquanto as áreas cuja presença de vegetação é nula, como por exemplo, a neve e água, haverá um maior

contraste, apresentando valores negativos. Por conseguinte, os valores próximos de 0 correspondem ao solo nu e áreas rochosas (Lillesand *et al.*, 2004 em Oliveira 2011).

Em comparação a outros índices de vegetação, a popularidade do NDVI deve-se também à sua capacidade de “(...) redução de muitas formas de ruídos, *e.g.* diferenças de iluminação, sombras de nuvens, atenuações atmosféricas, algumas variações topográficas, etc., presentes em dados multiespectrais e multitemporais.” (França *et al.*, 2012).

b) Normalized Difference Water Index (NDWI)

Originalmente publicado por McFeeters (1996), o índice normalizado da diferença de água (*NDWI*) foi desenvolvido para realçar os corpos de água e reduzir a influência do solo na vegetação. Tem a capacidade de detetar as águas de superfície em ambientes húmidos e permite a medição da extensão da superfície de água (McFeeters, 2013). Assumindo princípios semelhantes aos do *NDVI*, os valores também variam entre -1 e 1. Porém, enquanto o *NDVI* utiliza a banda do vermelho, cuja reflectância é afetada pela clorofila, no *NDVI* é utilizada a banda do verde (0,533µm a 0,590µm) que apresenta uma grande sensibilidade na presença de sedimentos em suspensão (Tabela 7.2). No caso do Landsat 8 o *NDVI* é calculado através da banda 3, que corresponde ao Verde (*VD*), e da banda 5, que corresponde ao Infravermelho Próximo e expressa-se como:

$$NDWI = \frac{VD - IVP}{VD + IVP} \quad (7.2)$$

Tal como foi explicitado na *alínea a)*, com o *NDVI* a presença de vegetação e solo é reforçada, enquanto a presença de corpos de água e outras superfícies com característica de água é suprimida. No que diz respeito ao *NDWI*, além da alteração de comprimentos de onda a detetar, devido à troca da banda *V* pela *VD*, verifica-se também uma inversão na equação. Estas alterações provocam a supressão da vegetação e o destaque dos corpos de água.

Desta forma, aquando a presença de valores superiores a 0 assume-se que os mesmos representam superfícies de água/corpos de água, enquanto valores inferiores ou iguais a 0, representam superfícies de não-água, como o solo e vegetação terrestre.

c) Enhanced Built-Up and Bareness Index (EBBI)

O Índice otimizado de aridez e construção (*EBBI*) resulta, na situação particular do Landsat 8, da relação entre a banda 6, que corresponde ao Infravermelho de comprimento de onda curto (*IVOC1*), a banda 5, que corresponde ao Infravermelho próximo, e por fim a banda 10, que corresponde ao infravermelho térmico 1 (*IVT1*), sendo traduzido por (7.3):

$$EBBI = \frac{IVOC1 - IVP}{10\sqrt{IVOC1 + IVT1}} \quad (7.3)$$

Os comprimentos de onda médios destas bandas rondam os 0.83µm, 1.65µm e 11.45µm (*IVP*, *IVOC1* e *IVT1*, respetivamente). Estes comprimentos de onda foram selecionados com base na amplitude de contrastes de reflexão e absorção em áreas urbanas e de solo a nu. Segundo Herold *et al.* (2004), os valores de reflectância das áreas construídas são mais elevados devido às características dos sensores utilizados, *i.e.*, operam em maiores comprimentos de onda. O *IVP* e o *IVOC1*, são as que mais contribuem para o contraste na deteção das áreas de solo nu e construídas, e em pormenor, a banda *IVOC1* permite distinguir as áreas construídas da vegetação.

O comprimento de onda *IVP* está associado com um nível de alto contraste para detetar áreas urbanizadas e solo a nu. Além disso, nas bandas *IVOC1* e *IVP*, há uma relação inversa entre a reflectância das áreas de solo a nu e da vegetação. A Vegetação tem uma elevada reflectância na banda *IVP* mas em contraste a reflectância da área construída ou de solo a nu é baixa. Em oposição, na banda *IVOC1*, há alta reflectância por parte das áreas construídas em comparação com as áreas com vegetação (Herold *et al.*, 2003). De acordo com Weng (2008), a utilização da banda *IVT1* é muito eficaz para mapeamento de áreas construídas, onde um baixo albedo permite eliminar o efeito de sombras e as zonas de água, e um alto albedo destaca claramente as áreas urbanizadas e de solo a nu. A banda *IVT1* também apresenta um alto nível de contraste para a

vegetação. A temperatura de uma área construída é de 10–12 graus Celsius superior à da vegetação (Lu e Weng, 2006).

Combinando os três comprimentos de onda já indicados, a subtração do *IVOC1* pela banda *IVP* resultará em valores positivos para os píxeis correspondentes a áreas construídas e de solo a nu e em valores negativos para a vegetação. Além disso, a soma das bandas *IVP* e *IVT1* resultará em píxeis de valores mais elevados para solo urbanizado e a nu do que para a vegetação. O rácio entre a subtração e a soma de banda resultará virtualmente em nenhum píxel de água, bem como valores negativos para a vegetação e valores positivos para os píxeis correspondentes a solo urbanizado ou a nu. Este resultado permite a fácil distinção entre as áreas urbanizadas e de solo a nu.

Para alcançar um maior nível de contraste, foi introduzida uma pequena modificação na equação. Aplica-se a uma função de raiz ao denominador para criar *clusters* de objetos com contrastes idênticos baseados em diferentes níveis de valores de reflectância. Para obter um valor de índice de – 1 a 1, o numerador é dividido por dez.

d) Rácio 35

O Rácio 35 é um quociente entre a banda 3 (*VD*) e a banda 5 (*IVP*) e tem a capacidade de detetar a vegetação que apresenta uma reflectância entre 0,533µm a 0,590µm e 0,581µm a 0,879µm, respetivamente. O seu valor é dado por:

$$\text{Rácio 35} = \frac{VD}{IVP} \quad (7.4)$$

Pelo facto de não ser um índice normalizado, o Rácio35 não apresenta limites fixos, *i.e.*, os valores variam consoante a área onde é aplicado. Porém, analogamente ao NDVI, os valores mais elevados correspondem às áreas de vegetação, enquanto os valores mais baixos referem-se às áreas urbanizadas e sem coberto vegetal.

e) M 810

A variável *M810* foi construída especificamente para melhorar a classificação de determinados elementos de vegetação. A variável corresponde à média entre a banda 8 (Pancromática [*Pan*]) e a banda 10 (Infravermelho térmico 1), como se pode verificar em:

$$M810 = \frac{Pan + IVT1}{2} \quad (7.5)$$

A *M810* foi utilizada para retirar áreas de vegetação que se encontravam sobre efeito da sombra causada pela orografia da superfície. Estas áreas eram confundidas com os corpos de água, porque a sua cor tornava-se mais escura e a sua temperatura diminuía. Assim, utilizou-se a banda do *IVT1* que se identificou ser a que mais contribuiu para determinar o contraste entre a vegetação e os corpos de águas dos restantes elementos presentes na superfície terrestre, devido à reflectância e absorção de energia dos mesmos. No entanto, de forma a dar um maior destaque à vegetação recorreu-se à banda pancromática que contribui para uma maior resolução espacial, permitindo atribuir valores mais elevados à vegetação à sombra e sucessivamente valores mais baixos aos restantes elementos.

7.2.2. Identificação de limiares

Após uma exaustiva procura sobre quais as melhores variáveis para a extração das classes pretendidas, e quais os limiares (*thresholds*) a definir para a sua classificação, termina-se o processo de classificação das 4 imagens de treino. Na Tabela 7.3 estão representadas as variáveis e respetivos limiares de decisão na extração das classes.

No que concerne à função aplicada a cada uma das variáveis, cada vez mais a literatura se refere à lógica difusa como um dos caminhos a seguir nas metodologias baseadas em OBIA (*cf.* secções 4.4.5 e 5.1). A lógica difusa também chamada de lógica imprecisa/incerta confere graus intermédios de verdade para todas as afirmações. Esta perspetiva leva a que as afirmações difusas (*fuzzy*) sejam classificadas com níveis de

verdade intermédios entre absolutamente verdadeiro e completamente falso (que são as classificações extremas, também possíveis).

Um dos exemplos da maneira de pensar da lógica difusa (Kosko, 1992), remete para o paradoxo clássico do mentiroso de Creta que diz que todos os habitantes de Creta são mentirosos. Se o que ele diz for verdade, então ele é um mentiroso (mas diz a verdade!). Se ele estiver a mentir, então a frase é verdadeira e ele não é mentiroso (mas acabou de dizer uma mentira). A lógica difusa permite explicitar que no que respeita à realidade, as leis da matemática não são exatas. Quando o são, não se referem à realidade.

De facto, as transições entre conceitos reais não são abruptas. Os conceitos são, muitas vezes, subjetivos e existem zonas de transição entre conceitos diferentes, bem definidos e bem conhecidos. Essa é a ideia da lógica difusa, não fica apenas restrita à dicotomia entre verdadeiro e falso, mas sim à existência de vários níveis entre o verdadeiro e falso. De modo figurativo enquanto a lógica clássica visualiza apenas o preto e o branco, a lógica difusa é capaz de, além do preto e o branco, identificar vários níveis de cinzento.

A lógica difusa fornece novas maneiras de lidar com a incerteza e a imprecisão nos modelos. A maneira tradicional de lidar com a incerteza – a aplicação das teorias da probabilidade e da estatística – obteve sucesso em um grande número de casos. No entanto, o uso dessas teorias para modelos complexos requer uma grande quantidade de hipóteses teóricas e geralmente torna-se extremamente difícil e inaplicável a propósitos práticos (Bárdossy e Duckstein, 1995). À medida que a complexidade de um certo sistema aumenta, a capacidade para fazer afirmações significativas do seu comportamento diminui até se atingir um ponto de transição, a partir do qual precisão e significado (relevância) se tornam mutuamente exclusivos (Cox, 1994).

Neste sentido, e face às características das imagens Landsat 8, nomeadamente a sua resolução espacial (píxel de 900 m²), verificou-se que as funções difusas não acrescentavam mais-valias ao processo de classificação, isto porque a existência de inúmeros míxeis (*cf.* secção 7.1) leva a que a imagem *per si* já contenha bastante informação difusa. Assim, optou-se por utilizar funções lineares crescentes (\lceil) e decrescentes (\lfloor).

Tabela 7.3 - Variáveis e respectivos limiares para a classificação das 4 imagens de treino

Variáveis	Limiar por imagem			
	27 novembro 2013	10 outubro 2013	23 agosto 2013	22 julho 2013
	Função			
LD-Banda 1	8348,70	9368,70	10723,70	11384,00
LD-Banda 4	6619,00	7340,60	9002,80	12056,60
LD-Banda 5	5333,00	5397,00	13482,00	14015,00
LD-Banda 6 (1)	6017,00	9227,00	10551,00	10164,00
LD-Banda 6 (2)	6564,50	9906,00	12195,00	10712,50
LD-Banda 6 (3)	8379,50	9906,00	12195,00	15222,50
LD-Banda 7	8908,70	10759,30	12474,70	12772,30
LI-Banda 8	13049,57	13049,57	13049,57	13049,57
LD-Banda 11	18467,00	23925,00	24378,00	23729,00
Radiométricas				
Desvio padrão	141,27	220,37	250,60	271,00
LD-NDVI	0,18	0,20	0,27	0,20
LD-NDWI (1)	0,02	0,00	0,00	0,00
LD-NDWI (2)	-0,02	-0,11	-0,11	-0,12
LD-NDWI (3)	-0,10	-0,12	-0,12	-0,10
LD-M 8_10	13453,00	16044,00	15911,00	15000,00
LD-Rácio 3_5	0,59	0,59	0,46	0,47
Geometria				
LI-Area (1)	400,00	400,00	400,00	400,00
LI-Area (2)	3400,00	3400,00	3400,00	3400,00
LI-Area (3)	3000,00	3000,00	3000,00	3000,00
LD-Area (4)	628,00	69,00	31,00	100,00
LI-Area (5)	10,00	10,00	10,00	10,00
LI-Distance	27,00	27,00	27,00	27,00
Relação de classes				
LI-Relative border (1)	0,00	0,00	0,00	0,00
LI-Relative border (2)	0,00	0,00	0,00	0,00
LD-Relative border (3)	0,18	0,19	0,08	0,15

┌ Função linear crescente

└ Função linear decrescente

*LD - variável com limiar dependente da imagem

*LI - variável com limiar independente da imagem

*M - Média de uma variável

*DP - Desvio Padrão de uma variável

7.3. Algoritmo de classificação

No âmbito dos objetivos pretendidos, foram realizadas várias tentativas de classificação de forma a melhorar o algoritmo em dois aspetos: *i*) modificação e/ou substituição de variáveis para uma melhor extração das classes; *ii*) simplificação do algoritmo, reduzindo e alterando a ordem dos processos. Na Tabela 7.4, encontram-se descritas as alterações feitas no que diz respeito ao ponto 1.

Tabela 7.4 - Descrição das alterações realizadas ao longo dos vários algoritmos de classificação

Algoritmo	Alterações
2	Eliminação da variável EBBI que ajudava a captar mais áreas de vegetação. Adição da variável LD-Banda 7 para retirar as áreas da classe zonas descobertas e com pouca vegetação das áreas de vegetação;
3	Substituição da lógica difusa apenas para a variável LD-DP Banda 1 na classe Territórios artificializados; Eliminação da variável LD-Banda 1 (2) no auxílio da classificação da classe Territórios Artificializados.
4	Substituição da variável <i>Border index</i> para a LI-Area (2) para classificar as Águas Interiores; Substituição das variáveis LD-Banda 6 para LD-Banda 2 para classificar as Zonas húmidas litorais.
5	Adição da variável LI-Area (1) para a classificação da sombra das nuvens; Eliminação de uma variável LD- <i>Relative border</i> na classe Territórios artificializados.

Para a classificação de uma imagem através da abordagem baseada em objeto, é exigida uma forte técnica de fotointerpretação, “(...) na medida em que alguns dos atributos de classificação dos objetos passam pelo uso dos conceitos de variáveis visuais, como a forma, a cor, a textura, a associação, etc.” (Encarnação, 2004). Porém, foram as variáveis baseadas na informação espectral que maior contributo deram para a extração de cada classe. Apesar da disponibilidade de uma grande diversidade de variáveis baseadas na forma dos objetos, estas foram preteridas uma vez que limitavam muito o algoritmo à imagem, *i.e.*, eram de difícil aplicação multitemporal pois devido à dinâmica da ocupação do solo os objetos não apresentam sempre as mesmas dimensões e formas. Além disso, a própria resolução espacial utilizada, implica a criação de objetos de grandes dimensões (mínimo de 900 m² equivalente a 1 píxel) e de formas normalizadas.

Pode-se assim considerar que predominou o que Eastman (2009) apelida de classificação baseada em segmentos. Esta abordagem agrupa os píxeis adjacentes da imagem em

segmentos de acordo com a sua similaridade espectral, sendo que o confinamento da imagem em objetos é efetuado com base na variância dos NI da imagem. O objetivo do processo de segmentação é agrupar as unidades mínimas da imagem, *i.e.*, píxeis, noutras mais significativas para a sua interpretação/classificação e, deste modo, melhorar os valores de exatidão global.

Apesar de tudo, nesta dissertação o grande contributo que abordagem baseada em objeto, diz respeito à segmentação multiresolução. Esta técnica agregada à informação espectral dos objetos criados, forneceram a informação necessária à construção de um algoritmo transponível e replicável de classificação de imagens. Relativamente às classes que se pretendia identificar foram estabelecidos seis pressupostos:

a) Nuvens e Sombras

Na extração das nuvens utilizou-se, em primeiro lugar, a banda 8 (LI-Banda 8) para classificar todos os objetos pertencentes a esta classe. De seguida recorreu-se ao algoritmo *Merge Region*, de forma a agrupar todos os objetos de ‘nuvens’ que sejam contíguos. Estes novos objetos de maior dimensão apresentam um maior contraste em comparação aos restantes objetos da imagem. Com a banda 11 (LI-Banda 11) foi então possível excluir os objetos que não fazem parte da classe nuvens. Para a extração da sombra, recorreu-se à variável *Distance to Nuvens*, de forma a selecionar os objetos que se encontram a uma distância suficientemente abrangente para englobar os objetos de sombra pretendidos. Em conjunto com o *Distance to Nuvens* utilizou-se a banda 5 (LD-Banda 5) para excluir os objetos que se encontram até à mesma distância que as áreas de sombra, mas que não partilham das mesmas características. De seguida, com o *Merge Region* agruparam-se todos os objetos classificados como sombra das nuvens e com uma variável de Área (LI-Area (1)) foram mantidos apenas os objetos com dimensão superior à unidade mínima cartográfica.

b) Águas interiores / Águas marinhas e costeiras

Inicialmente utilizou-se o índice *NDWI (LI-NDWI (1))* para classificar todos os objetos referentes aos corpos de água. De seguida, através do algoritmo *Merge Region* foram agrupados todos os objetos num só, e com a variável Área (LI-Area (2) (3)) fez-se a distinção

entre as águas marinhas e costeiras. As águas interiores e os restantes corpos de água que foram assumidos como águas interiores.

Porém, a classe 'águas interiores' só ficou completa após a classificação da classe 'Zonas húmidas litorais'. Utilizou-se mais uma vez uma variável de área (LI-Areas (4)) para este processo. É de notar que não foi possível a classificação completa sem classificar as zonas húmidas litorais, porque estes últimos objetos a incluir apresentavam uma assinatura espectral ligeiramente diferente que os objetos localizados pelo *NDWI*, *i.e.*, existia uma combinação perniciososa de elementos/ruído que contribuía para uma diferenciação indesejada da reflectância destes corpos de água.

c) Áreas agrícolas e agroflorestais / Florestas e meios naturais e seminaturais

A classe 'áreas agrícolas e agroflorestal' em conjunto com a classe 'florestas e meios naturais e seminaturais', apresentaram um processo de classificação bastante simples. Além de constituírem as áreas de ocupação do solo com maior extensão na área de estudo, os seus objetos apresentam dimensões maiores e conseqüentemente um maior contraste em relação às outras áreas. Assim, começou-se por classificar toda a área relativa à vegetação com o uso do índice *NDVI* (*LD-NDVI*).

Posteriormente, com o auxílio da banda 4 (*LD-Banda 4*) foi dada continuidade à classificação da vegetação. Esta foi repartida por duas classes: 'áreas agrícolas e agroflorestais', e 'florestas e meios naturais e seminaturais', através do cálculo do rácio da banda 3 e 5 (*LD-Rácio 35*).

Mais detalhadamente, a classe 'florestas e meios naturais e seminaturais' inclui mais objetos para além dos discriminados no processo anterior, *i.e.*, quando foi eliminado o ruído na classe das 'águas interiores'. Para obter estes novos objetos utilizou-se uma variável referente à média das bandas 8 e 10 (*LD-Média 810*) para extrair os objetos pertencentes à classe 'florestas e meios naturais e seminaturais' que estavam classificados como 'águas interiores'.

d) Zonas húmidas litorais

A classificação da classe ‘zonas húmidas litorais’ foi realizada através de uma abordagem diferente em comparação às outras classes. Devido à dificuldade de extrair os objetos através da sua assinatura espectral, recorreu-se à sua proximidade com os corpos de água, *e.g.*, as zonas húmidas litorais são áreas que apresentam uma relação de vizinhança com os corpos de água. Assim, utilizou-se a variável *Relative Border* (LI-Relative Border (1) to Corpos de água) que permitiu localizar os objetos que se encontravam adjacentes aos corpos de água, e com o *NDWI* (LI-NDWI (2)) e a banda 6 (LI-Banda 6 (2)) foram classificados apenas os objetos que faziam parte da classe ‘zonas húmidas litorais’. Porém, neste processo apenas foram classificadas sementes (*seeds*), *i.e.*, objetos de amostra da classe que se pretende classificar. Através das *seeds* foi novamente utilizado o *Relative Border* (LI-Relative Border (2) to Zonas húmidas litorais) mas desta vez procurou-se localizar os objetos adjacentes às zonas húmidas litorais já conhecidos. Utilizou-se novamente o *NDWI* (LI-NDWI (3)) e a banda 6 (LI-Banda 6 (3)) para serem incluídos apenas os objetos pretendidos.

Para terminar o procedimento, como este apenas se dirigiu a objetos vizinhos e não se traduziu num efeito de propagação, foi necessário utilizar o algoritmo de classificação *Find Enclosed by Class*. Este algoritmo permitiu localizar e classificar os objetos da imagem que se encontram completamente rodeados por objetos da classe em análise. Deste modo, foi possível classificar todos os objetos referentes às ‘zonas húmidas litorais’. No entanto, foram inadequadamente incluídos alguns objetos relativos à classe ‘águas litorais’, devido à sua semelhança espectral. De forma a distinguir estes objetos, procedeu-se ao *Merge Region* para que com uma variável de área (LI-Area (4)) essa separação fosse possível, pois as zonas húmidas litorais compreendem objetos de menores dimensões que a classe águas litorais.

e) Territórios artificializados

Devido à dimensão de píxel utilizada e às características intrínsecas da área de estudo, os objetos referentes aos ‘territórios artificializados’ apresentam uma dimensão muito reduzida. Este facto contribui para uma maior dificuldade na classificação desta classe, uma vez que os objetos são constituídos por um pequeno grupo de píxeis com um fraco contraste

espectral. No entanto, com o desvio padrão da banda 1 (LD-DP Banda 1) foi possível classificar a maioria dos objetos pertencentes à classe Territórios Artificializados. Contudo, ficavam ainda por incluir muitos objetos de pequenas dimensões situados no interior dos objetos já classificados. Para obviar a esta situação, recorreu-se a um algoritmo do eCognition® o *Find Enclosed by Class*

No entanto, nem todos os objetos que se encontravam rodeados por ‘territórios artificializados’, pertenciam a essa mesma classe. Assim, foi estabelecida uma área (LI-Area (5)) limite para evitar que objetos de outras classes de ocupação do solo sejam classificados como ‘territórios artificializados’.

De seguida, efetuou-se um *Merge Region* para agrupar todos os objetos com contato entre si, para que fosse possível efetuar outro processo de eliminação de ruído com recurso à banda 1 (LD-Banda 1), excluindo da classe objetos sem expressão.

f) Zonas descobertas e com pouca vegetação

A classe referente às ‘zonas descobertas e com pouca vegetação’ foi a última a ser extraída, e não necessitou de muitos passos para ser classificada. Toda a área que ficara anteriormente por classificar, foi classificada como ‘zonas descobertas e com pouca vegetação’, porque todas as outras classes já estavam extraídas. Porém, esta abordagem não estava isenta de problemas e ainda houve a necessidade de retirar, com o auxílio da banda 7 (LI-Banda 7), alguns objetos que no processo de localização da ‘vegetação’ foram incluídos na classe referente aos ‘territórios artificializados’. Observaram-se também alguns objetos entre os ‘territórios artificializados’ e as ‘águas litorais’ que pertenciam à classe ‘zonas descobertas e com pouca vegetação’. Para resolver esta situação, utilizou-se a variável *Relative Border* (LI-Relative Border (3) to águas Litorais). O processo completo de classificação encontra-se esquematizado na Figura 7.1.

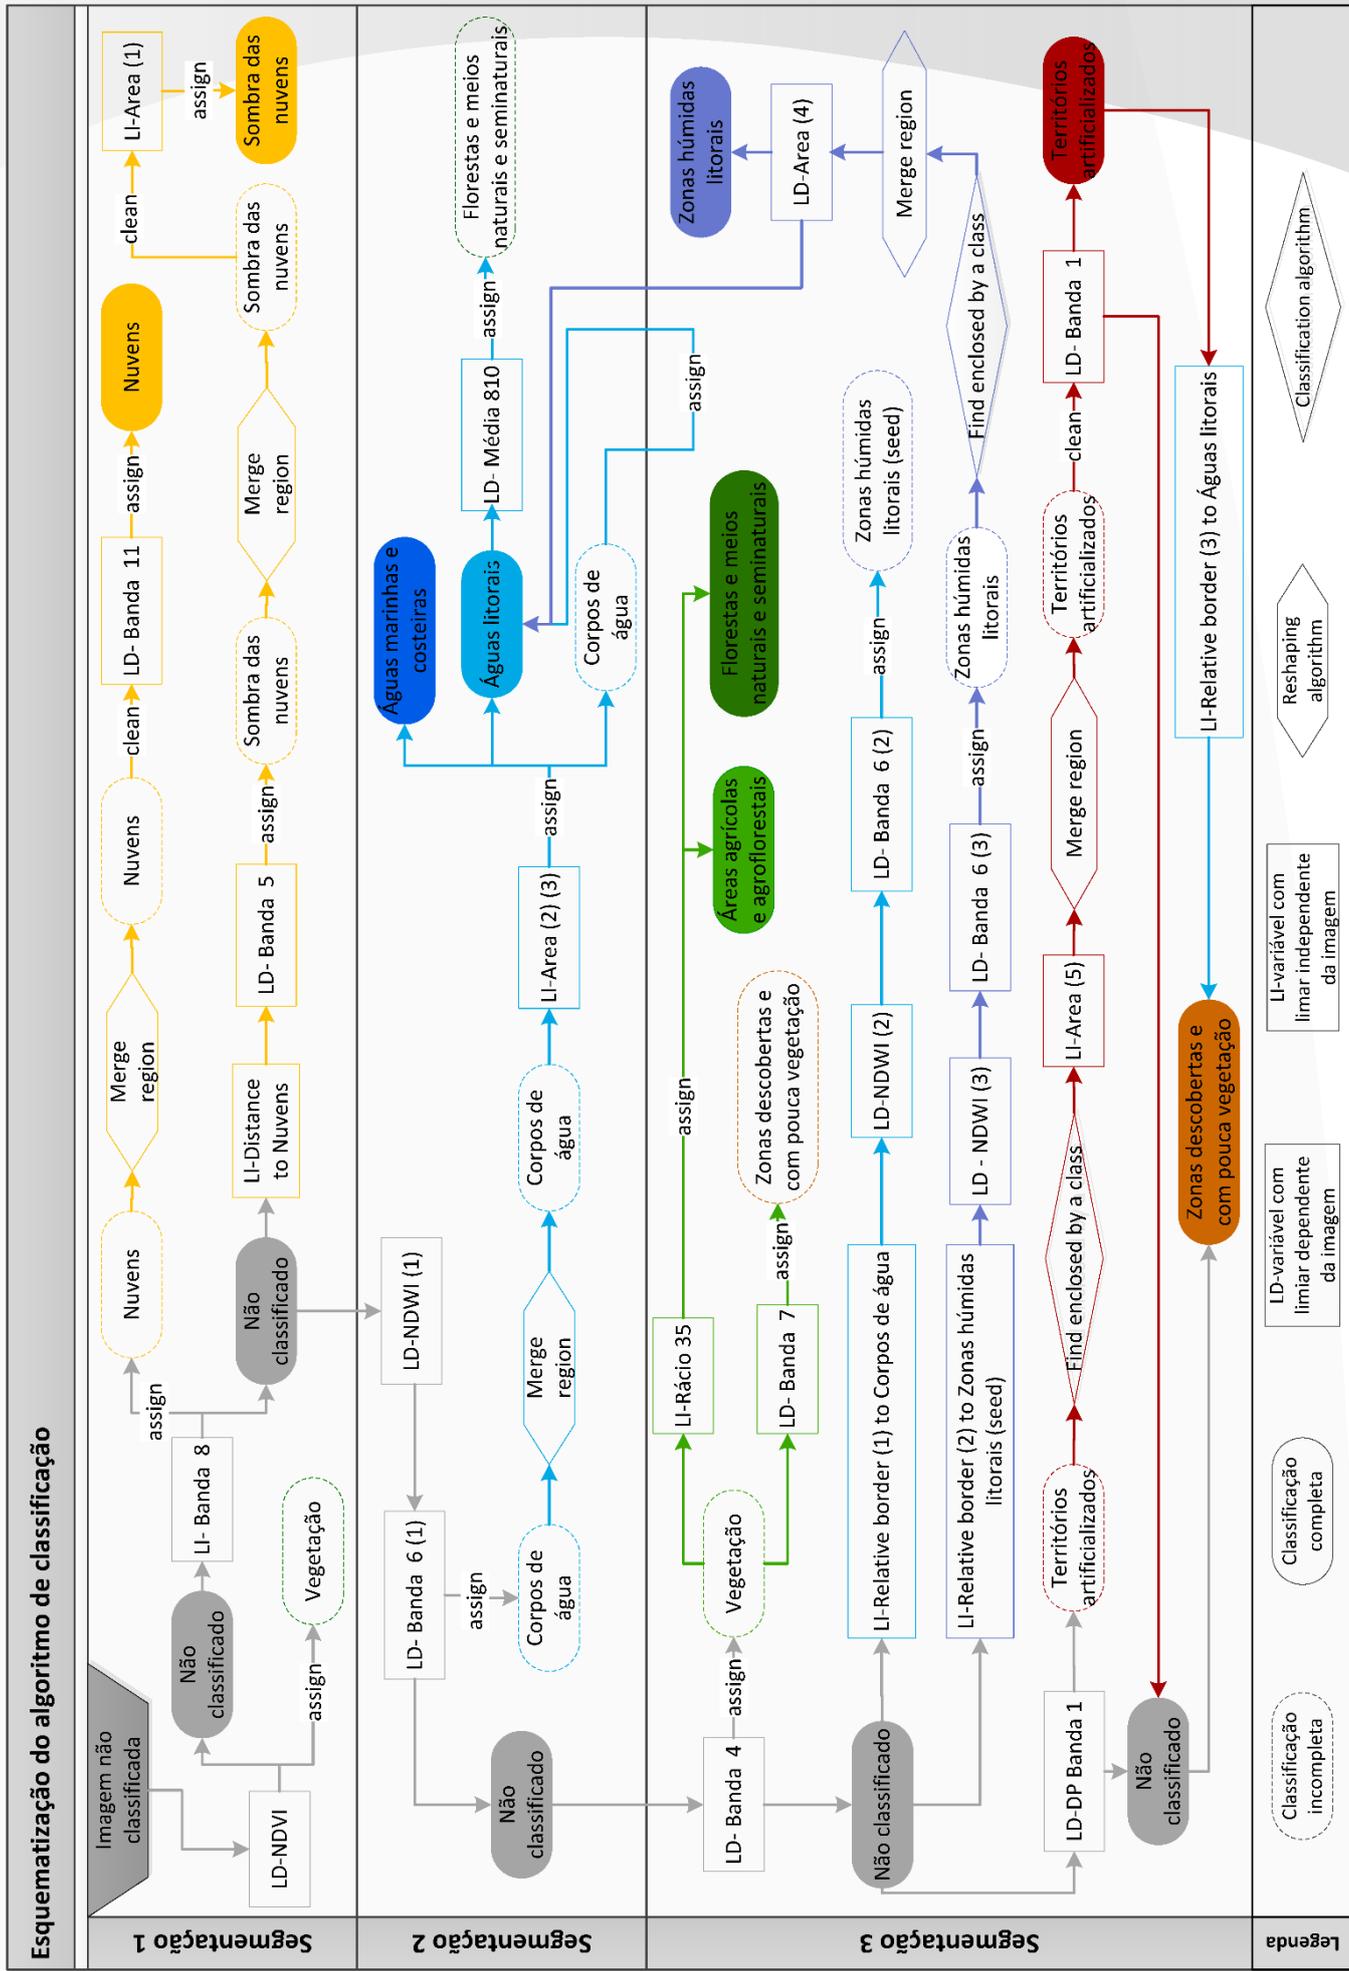


Figura 7.1 - Esquematisação do algoritmo de classificação

7.4. Determinação semiautomática de limiares

A Análise por Componentes Principais (ACP), também referida como Transformada Discreta de Karhunen-Loève (KLT, 1955) ou Transformada de Hottelling, em homenagem a Kari Karhunen, Michel Loève e Harold Hotelling, é uma das técnicas de análise multivariada mais simples e mais utilizadas em todo o Mundo (Arnold, 1991 em Yi e Marshall, 2000).

A ACP (ou PCA do inglês *Principal Components Analysis*) é um método estatístico de redução de dados através da eliminação de sobreposições, visando a representatividade dos dados através de combinações lineares das variáveis originais. Esta análise é considerada um método fatorial, porque reduz o número de variáveis através da construção de novas variáveis sintéticas, obtidas pela combinação linear das variáveis iniciais e não através de uma seleção de variáveis. Também possibilita, “a identificação das medidas responsáveis pelas maiores variações entre os resultados, se, perdas significativas de informações” (Vicini, 2005), eliminando as variáveis originais que possuem pouca informação.

A ideia base é a de comprimir a informação de um determinado conjunto de dados multivariados, reduzindo a dimensionalidade da informação, obtendo “(...) um volume menor de dados, que por definição, são independentes e não-correlacionados” (Messina e Crewes-Meyer, 2005). A transformação de dados com ACP foi criada precisamente para reduzir a redundância dos dados (Lilesand *et al.*, 2004 em Oliveira, 2011), remover o “ruído” (Eastman, 2006 em Oliveira, 2011) e, conseqüentemente, aumentando a eficiência computacional.

Em detecção remota, a ACP é particularmente útil porque reduz a grande correlação existente entre as bandas da maior parte das imagens de satélite. Assim, o propósito deste procedimento é o de comprimir toda a informação contida num conjunto de n bandas num outro de dimensão igual ou inferior a n . Na prática, a ACP é uma transformação ortogonal, assente numa matriz de variância-covariância (Σ) ou numa matriz de correlação (R), de onde são extraídos os valores próprios e os vetores próprios, e através de combinações lineares são geradas as novas variáveis ordenadas

relativamente à variância (quantidade de informação), denominadas de Componentes Principais (CP). Cada componente principal é uma combinação linear de todas as variáveis originais, com independência estatística e não correlacionadas entre si. Esta transformação é utilizada para realçar a dimensionalidade escondida dos dados multiespectrais, através da já mencionada remoção da redundância. A Figura 7.2, serve de base para explicar a aplicação da ACP.

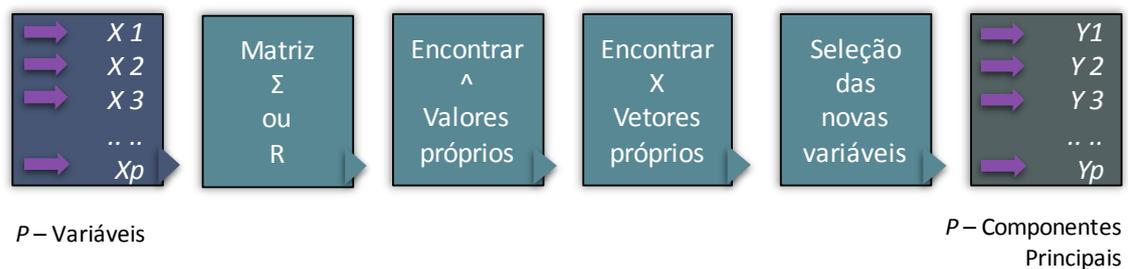


Figura 7.2 - Esquema da aplicação da análise por componentes principais (adaptado de Souza, 2000 em Vicini, 2005)

Por exemplo, ao analisar uma imagem de satélite, *e.g.* Landsat, é possível observar que existe uma forte correlação interbandas, *i.e.*, em determinadas áreas da imagem a mesma análise multiespectral pode ser realizada através de várias bandas. Esta correlação é bastante perceptível na Figura 7.3 onde se encontram representadas graficamente as variáveis X_1 , X_2 , X_3 , X_4 e X_5 no plano U_1 e U_2 , e o respetivo círculo de correlação.

Na análise ao círculo de correlações, são observadas as proximidades ou oposições entre as variáveis através da projeção das mesmas. Neste caso, as variáveis X_1 , X_2 , X_4 e X_5 estão bem representadas, porque se encontram próximas do limite da circunferência. Contudo, as variáveis X_1 e X_2 estão fortemente correlacionadas entre si devido à sua grande proximidade, mas são independentes das variáveis X_4 e X_5 , apresentando uma correlação negativa forte, *i.e.*, estão inversamente correlacionadas com a variável. Isto quer dizer que estes dois conjuntos de variáveis não explicam a mesma informação, mas sim informação oposta. Em relação à variável X_3 esta encontra-se mal representada neste plano, por não se situar próxima do limite da circunferência.

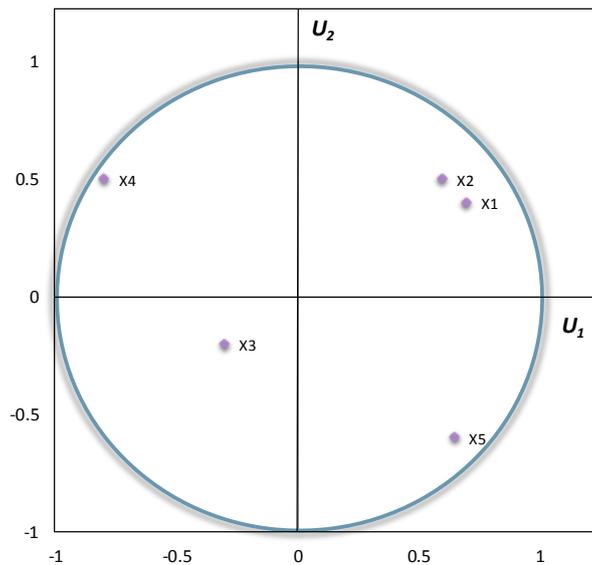


Figura 7.3 - Círculo de correlação

7.4.1. Cálculo dos limiares

Após a classificação prévia das imagens de treino, por tentativa e erro, e seleção visual dos limiares de corte das funções das variáveis de classificação, inicia-se o processo de automatização da classificação das imagens de teste. Para tal, procura-se determinar quais os limiares a introduzir no algoritmo de classificação.

O método proposto para automatizar o processo de classificação baseia-se na aplicação de duas ACP com dois objetivos diferentes. O primeiro objetivo diz respeito à identificação de um conjunto de parâmetros que caracterizem as imagens, designados de parâmetros *a priori*. Estes parâmetros correspondem aos valores de média e desvio padrão de todas as bandas do satélite Landsat 8, aos índices utilizados na construção do algoritmo de classificação, e a outros parâmetros relacionados com as condições de aquisição das imagens (altura e azimute do Sol). Os cálculos dos parâmetros *a priori* foram realizados em *Matlab*®. A recolha e cálculo de todos estes valores foram realizados para as oito imagens.

Posteriormente foi realizada uma ACP considerando como dados de entrada os valores dos parâmetros *a priori* e os valores dos limiares das variáveis dependentes das quatro imagens de treino. Nesta etapa, a ACP gera um círculo de correlação, capaz de

detetar a correlação entre os limiares das variáveis utilizadas nas imagens de treino e os parâmetros caracterizadores das suas propriedades (Figura 7.4).

A transformação ACP é aplicada a uma matriz Q, em que as linhas são as imagens de treino e as colunas são as variáveis cuja correlação se pretende avaliar. As CP são os vetores próprios da matriz $V=XX^T$, em que a matriz X resulta da normalização da matriz Q, a qual se torna necessária quando as variáveis possuem diferentes amplitudes, e.g. de 0 a 65 536 ou de -1 a 1. A correlação entre as variáveis é avaliada através da sua projeção no círculo de correlação, em que as variáveis altamente correlacionadas se organizam em aglomerados (*clusters*).

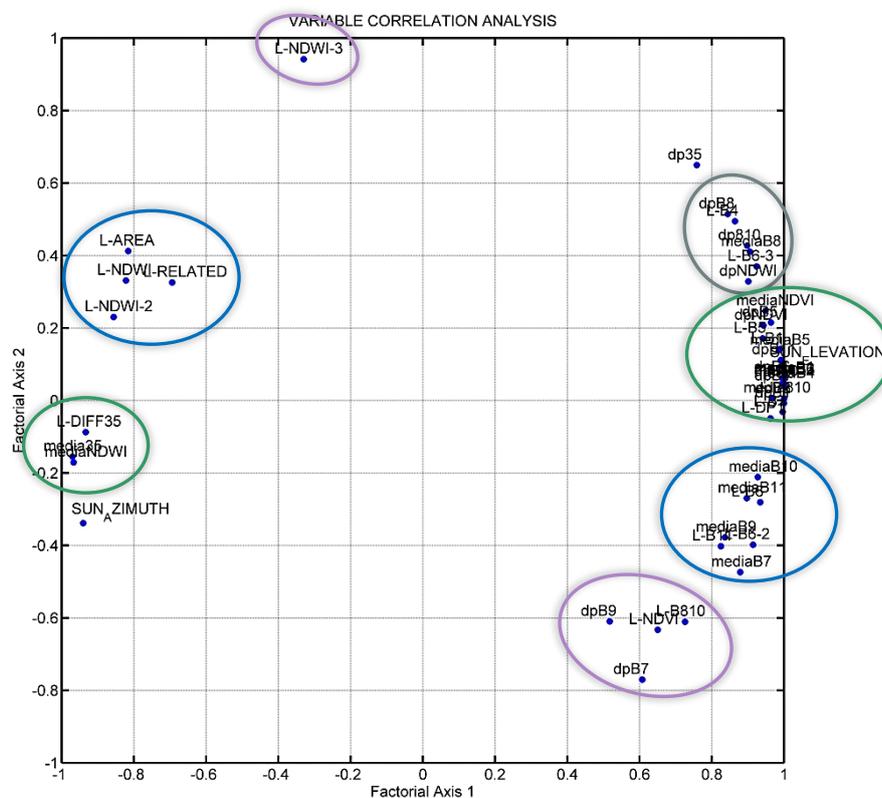


Figura 7.4 - Análise da correlação entre as variáveis para o conjunto de imagens de treino (1ª ACP)

Na Tabela 7.5, encontram-se descritas as variáveis e os parâmetros *a priori* que compõem cada *cluster* formado através do círculo de correlação. Aquando a formação dos *clusters*, espera-se que estes sejam descritos por variáveis e parâmetros *a priori*, mesmo que a sua correlação seja inversa. Em caso afirmativo isso significa que existem parâmetros *a priori* cujos valores são úteis na explicação do comportamento das

variáveis utilizadas e respectivos limiares. É de referir que no caso de um limiar ficar isolado no círculo de correlação, sem ter parâmetros *a priori* direta ou inversamente correlacionados, o algoritmo não permite estimar o seu valor.

Tabela 7.5 - Discriminação das variáveis e parâmetros *a priori* presentes em cada cluster formado através do círculo de correlações

Clusters				
	1	2	3	4
Variáveis diretamente correlacionadas	LD- Banda 4 LD- Banda 6 (3)	LD- Banda 5 LD- Banda 1 LD- Banda 7 LD- DP Banda 1	LD- Banda 6 LD- Banda 6 (2) LD- Banda 11	LD-NDVI LD-M 8_10
Variáveis inversamente correlacionadas		LD- Rácio 3_5	L- Area L- NDWI L- Relative border (4) L-NDWI (2)	LD-NDWI (3)
Parâmetros <i>a priori</i> diretamente correlacionados	P- DP Banda 8 P- DP M 8_10 P- M Banda 8 P- DP NDWI	P- M NDVI P- DP Banda 5 P- DP NDVI P- M Banda 5 P- DP Banda 11 P- Altura do Sol P- DP Banda 6 P- M Banda 1 P- M Banda 2 P- M Banda 6 P- M Banda 3 P- DP Banda 10 P- M Banda 4 P- DP Banda 4 P- M- 8_10 P- DP Banda 1 P- DP Banda 3 P- DP Banda 2	P- M Banda 10 P- M Banda 11 P- M Banda 9 P- M Banda 7	P- DP Banda 7 P- DP Banda 9
Parâmetros <i>a priori</i> inversamente correlacionados		P- M Rácio 3_5 P- M NDWI		

*LD – variável com limiar dependente da imagem; *P – parâmetros *a priori*

Depois de identificadas as variáveis com alta correlação (VAC), é realizada uma segunda ACP sobre o conjunto das imagens de treino, utilizando os parâmetros *a priori* para cada um dos *clusters* individuais. Para cada ACP realizada, foi obtida uma CP ao longo da qual as imagens de treino estão ordenadas. De seguida, as imagens de teste foram projetadas na mesma componente principal (sem terem tido qualquer influência na sua construção) à custa dos parâmetros *a priori* (Figura 7.5).

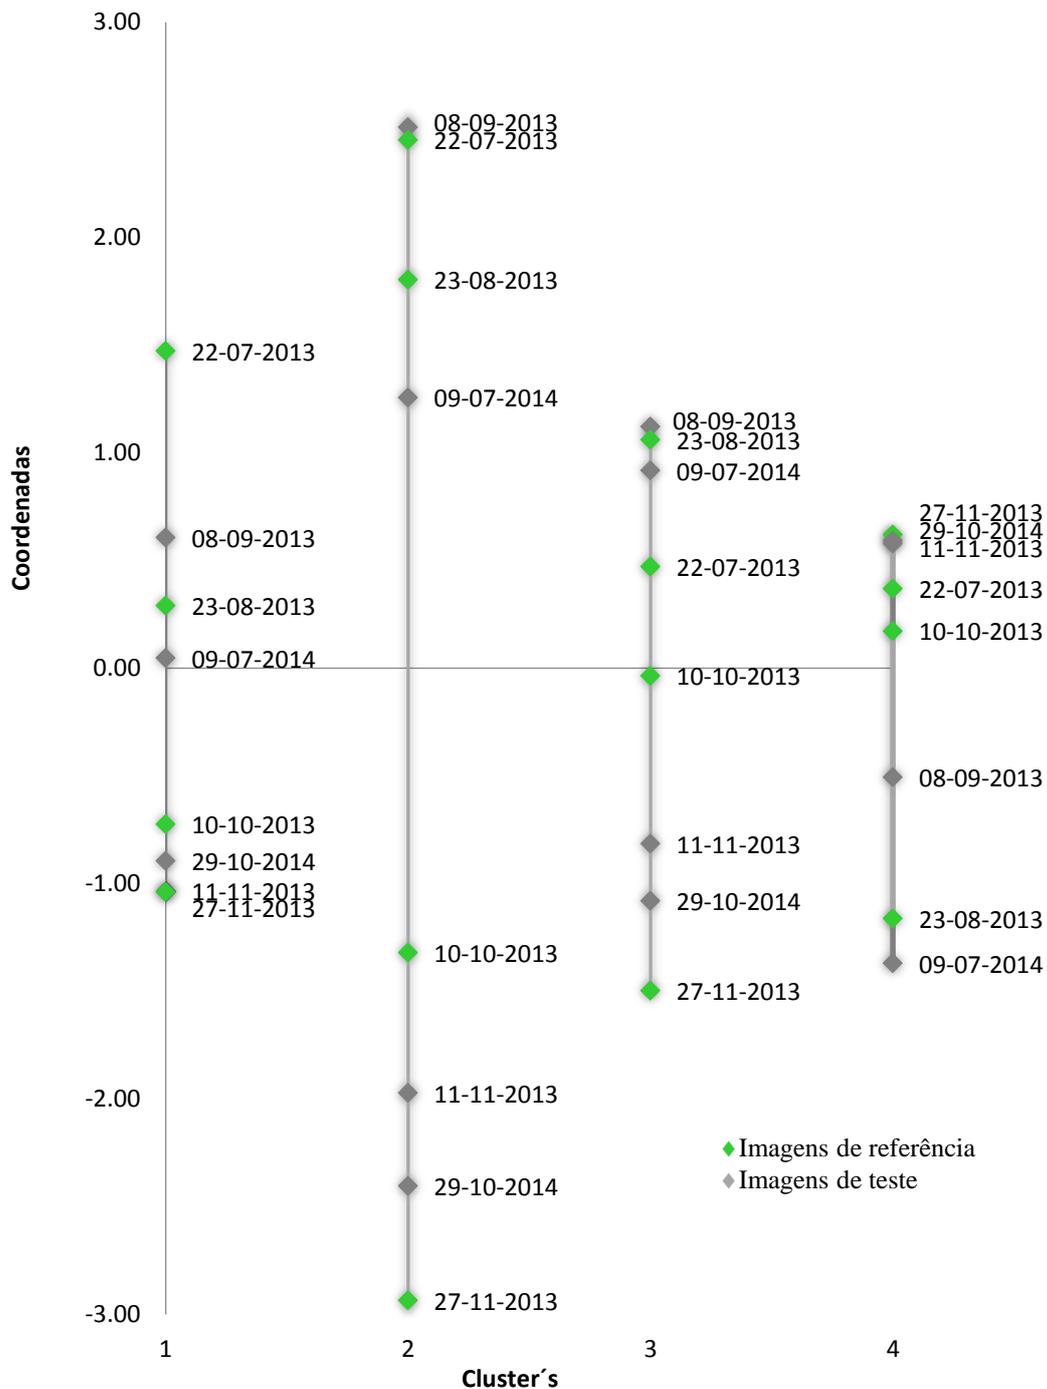


Figura 7.5 - Projeção das imagens de treino e de teste (2ª ACP)

Depois de projetadas as imagens, é realizada a interpolação dos limiares de corte a aplicar às imagens de teste com base nos valores dos limiares de corte das imagens de treino. Desta forma, foi possível determinar automaticamente os limiares para o restante conjunto de imagens da área de estudo (Tabela 7.6).

Tabela 7.6 - Variáveis e respectivos limiares para a classificação das 4 imagens de teste

Variáveis	Limiar por imagem			
	9 julho 2014	8 setembro 2013	29 outubro 2014	11 novembro 2013
	Função			
LD-Banda 1	└┘	11445,031	10997,359	8957,517
LD-Banda 4	└┘	9821,900	8603,8	6632,100
LD-Banda 5	└┘	14064,264	5499,190	5371,200
LD-Banda 6 (1)	└┘	10590,904	10457,073	7516,887
LD-Banda 6 (2)	└┘	12347,861	11835,188	8125,831
LD-Banda 6 (3)	└┘	13007,100	11645,6	8407,100
LD-Banda 7	└┘	12799,807	13714,198	10013,286
LI-Banda 8	└┘	13049,570	13049,57	13049,570
LD-Banda 11	└┘	24444,919	24220,483	21017,276
Radiométricas				
Desvio padrão	└┘	272,886	346,671	188,483
LD-NDVI	└┘	0,236	0,281	0,183
LD-NDWI (1)	└┘	0,000	0,000	0,011
LD-NDWI (2)	└┘	-0,109	-0,112	-0,062
LD-NDWI (3)	└┘	-0,119	-0,124	-0,100
LD-M_8_10	└┘	15976,403	15890,267	13703,770
LD-Rácio 3_5	└┘	0,471	0,590	0,590
Geometria				
LI-Area (1)	└┘	400,000	400,000	400,000
LI-Area (2)	└┘	3400,000	3400,000	3400,000
LI-Area (3)	└┘	3000,000	3000,000	3000,000
LD-Area (4)	└┘	23,885	47,747	366,805
LI-Area (5)	└┘	10,000	10,000	10,000
Posição	└┘	27,000	27,000	27,000
Relação de classes				
Relação com os objetos vizinhos				
LI-Relative border (1)	└┘	0	0	0
LI-Relative border (2)	└┘	0	0	0
LD-Relative border (3)	└┘	0,076	0,100	0,186
				0,184

7.4.2. Teste de sensibilidade à metodologia de classificação multitemporal

Após a projeção das imagens e o cálculo dos limiares das funções a utilizar no algoritmo das imagens de teste, realizou-se um teste à sensibilidade da metodologia de classificação multitemporal. Este teste consistiu em verificar as consequências para a qualidade das classificações de ocupação do solo da utilização dos limiares referentes às imagens de treino na classificação das imagens de teste, precavendo o cálculo de limiares específicos para cada imagem.

Para a seleção das imagens a utilizar neste teste, foi feita uma análise à sua projeção nas CP (Figura 7.5). Verificou-se que a projeção da imagem de teste de 9 de julho de 2014, na primeira CP se encontrava entre as imagens de treino de 23 de agosto de 2013 e de 10 de outubro de 2013, em 3 dos 4 *clusters*. Uma vez que não se encontrou outro conjunto de imagens com estas propriedades, foram então introduzidos os limiares das funções das duas imagens de treino no algoritmo de classificação da imagem de teste.

Capítulo 8 - Avaliação de resultados

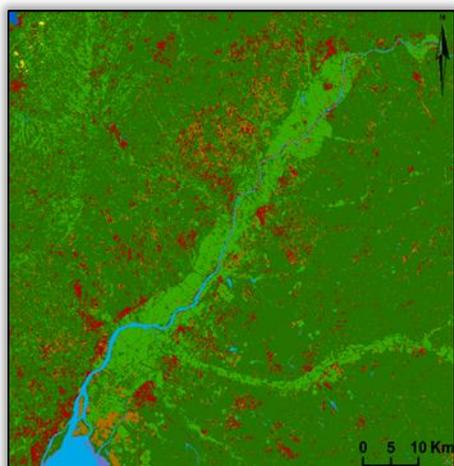
Neste capítulo são apresentados os mapas de ocupação do solo criados, e discutidos os resultados do cálculo das medidas de exatidão do utilizador (EU), exatidão do produtor (EP) e do coeficiente de concordância *Kappa* para cada classificação (cf. secção 8.2), e os erros de omissão (EO), erros de comissão (EC) e coeficiente de concordância *Kappa* para cada classe de ocupação do solo em cada uma das imagens (cf. secção 8.3). Por último, é também apresentado e discutido o resultado da avaliação da exatidão temática do teste de projecção.

8.1. Cartografia de ocupação do solo

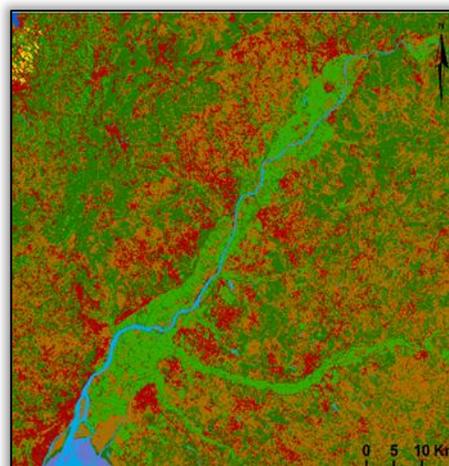
A partir dos mapas produzidos (Figura 8.1 e Figura 8.2), é possível retirar visualmente algumas conclusões mesmo antes de serem aplicadas as medidas de validação. Apesar de não ter sido feita a avaliação da exatidão temática da classe referente às nuvens e à sua sombra, esta claramente não é sinónimo de uma boa classificação. Efetivamente, a título de exemplo pode-se referir que a imagem de 8 de setembro de 2013 não possui elementos dessa classe (nuvens/sombra), mas após a aplicação do algoritmo observa-se a presença de objetos classificados como tal.

Este erro na classificação, deve-se ao facto desta classe não fazer sentir a sua presença nas 4 imagens de treino, mas sim em apenas 3. Como esta situação é única pode-se inferir que para efetuar uma boa classificação e extração das classes, é necessária a classificação de pelo menos 4 imagens de treino e que todas as classes de ocupação do solo devem estar representadas em cada uma das imagens de forma a ser recolhida informação suficiente para executar uma boa classificação.

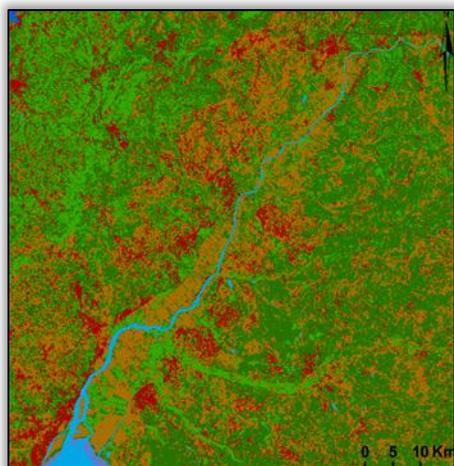
Em relação às classes de ocupação do solo, efetuaram-se os cálculos de avaliação da exatidão de forma a serem retiradas conclusões com maior credibilidade, em contraposição a uma simples análise visual.



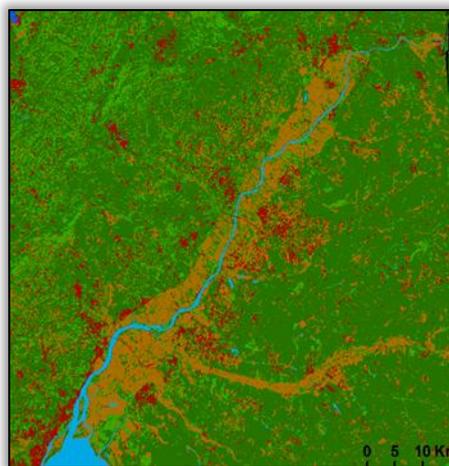
22 julho 2013



23 agosto 2013



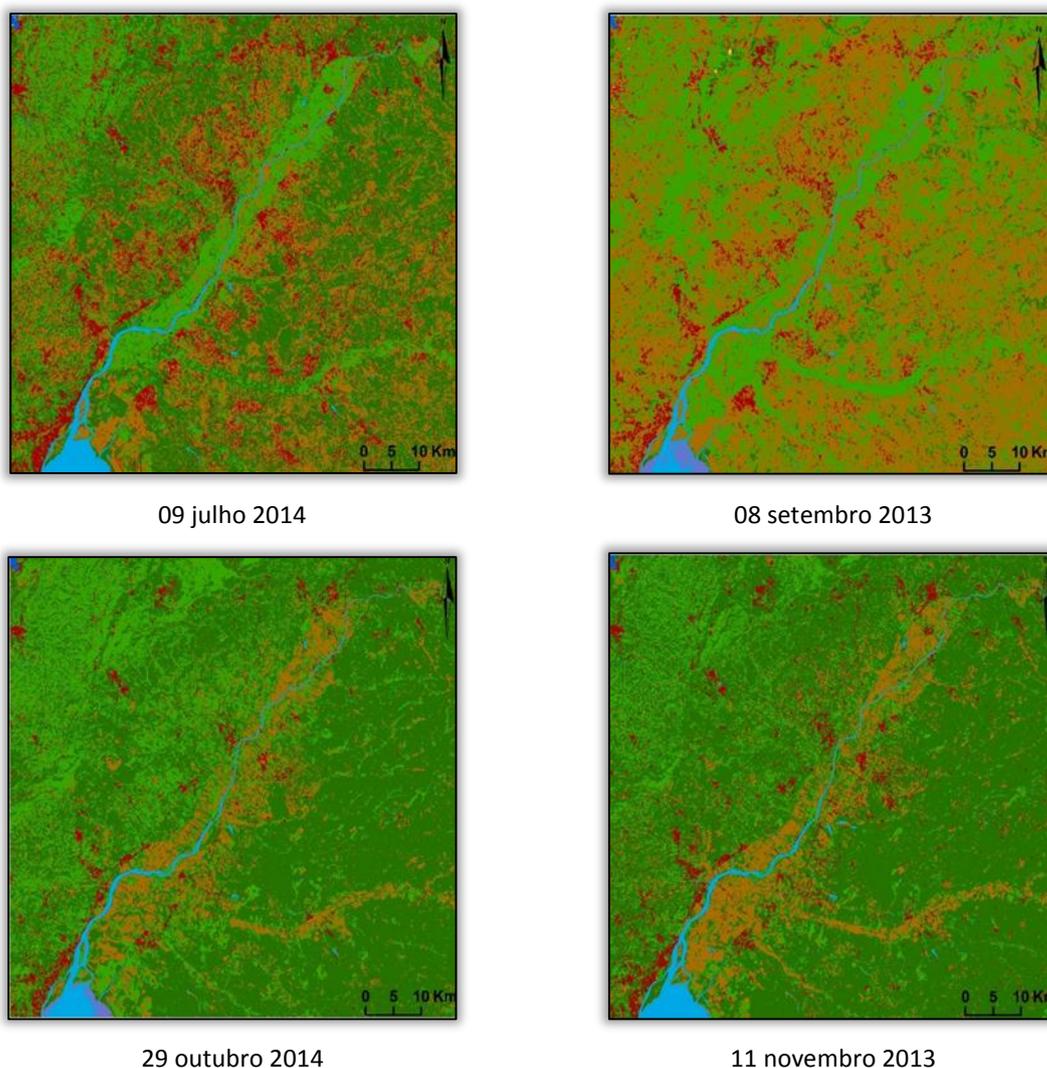
10 outubro 2013



27 novembro 2013

Designação da classe	
	Territórios artificializados
	Áreas agrícolas e agroflorestais
	Florestas e meios naturais e seminaturais
	Zonas descobertas e com pouca vegetação
	Zonas húmidas litorais
	Águas interiores
	Águas marinhas e costeiras

Figura 8.1 - Cartografia de ocupação do solo do conjunto de imagens de treino



Designação da classe	
	Territórios artificializados
	Áreas agrícolas e agroflorestais
	Florestas e meios naturais e seminaturais
	Zonas descobertas e com pouca vegetação
	Zonas húmidas litorais
	Águas interiores
	Águas marinhas e costeiras

Figura 8.2 - Cartografia de ocupação do solo do conjunto de imagens de teste

8.2. Avaliação da Exatidão Temática

Existem dois tipos de avaliação de exatidão que podem ser utilizados: a posicional e a temática. A primeira recorre à localização exata de um elemento num mapa, comparando-o com a posição em que esse mesmo elemento se encontra no mapa e na realidade. A

avaliação temática recorre aos atributos ou rótulos dos elementos do mapa e analisa onde é que eles diferem, ou não, do atributo real da imagem.

Na elaboração de mapas temáticos de ocupação do solo, nem sempre o resultado traduz a realidade com exatidão. De forma a avaliar a qualidade de uma classificação, deve-se submeter uma parte dos resultados a uma “(...) verificação experimental que, muito embora apenas possa ser parcial, servirá de orientação sobre a magnitude dos erros derivados do modelo e pode permitir a introdução de correções” (Rocha, 2012). É de notar que um mapa ou qualquer outro modelo só se torna válido depois de ser testado e avaliada a sua aptidão para representar ou projetar a informação pretendida. Para tal, recorre-se à avaliação da exatidão, ou seja, “(...) ao nível de correspondência entre o domínio fonte e o domínio alvo” (Rocha, 2012).

Começando por ser um processo simples, a avaliação da exatidão temática rapidamente evoluiu, tornando-se mais rigorosa e complexa. Inicialmente, “(...) a avaliação da exatidão era feita através de uma apreciação visual, o que é claramente subjetivo e inapropriado” (Costa, 2008). Atualmente, a avaliação da exatidão permite estimar a probabilidade de ocorrerem atribuições de classes corretas e a qualidade ou a confiabilidade do resultado de uma classificação. É um processo “(...) que resulta do confronto entre o mapa produzido com dados de referência, que se assume que representam a realidade” (Stehman *et al.*, 2000).

Um dos resultados possíveis deste processo é a produção de uma matriz de erro ou matriz de confusão, a partir da qual se podem derivar índices de exatidão global e temáticos (Jensen, 2000) e valores de avaliação específicos como os erros de comissão, erros de omissão e coeficiente de concordância *Kappa*. Segundo Congalton e Green (2009) não existe um procedimento único e padrão para a realização desta avaliação, porém esta deve incluir três passos fundamentais: *i*) Criação da amostra para a avaliação da exatidão; *ii*) Recolha de dados para cada amostra; e *iii*) Análise dos resultados.

8.2.1. Amostragem

A definição da estratégia de amostragem é uma etapa fundamental no processo de avaliação da exatidão temática (Lu e Weng, 2007). Na definição deste processo deve-se

considerar a unidade de amostragem, o esquema de amostragem e a dimensão da amostra (Lu e Weng, 2007; Congalton e Green, 2009). A unidade de amostragem é a unidade de base da avaliação que é confrontada com a unidade correspondente no mapa produzido. Geralmente, a unidade de amostragem é o píxel ou o polígono (Caetano *et al.*, 2002). O esquema de amostragem consiste no método de seleção das unidades da amostra de referência, o qual tem de garantir uma robustez estatística que só é atingida se o processo for probabilístico.

Existem várias técnicas para a extração de amostras das quais podemos destacar as regulares, as progressivas, as seletivas e as compostas. Qualquer uma destas técnicas tem por objetivo minimizar o esforço de recolha de dados ao mesmo tempo que viabilizam a validação das classificações. A Figura 8.3 mostra diferentes tipos de amostragem por pontos.

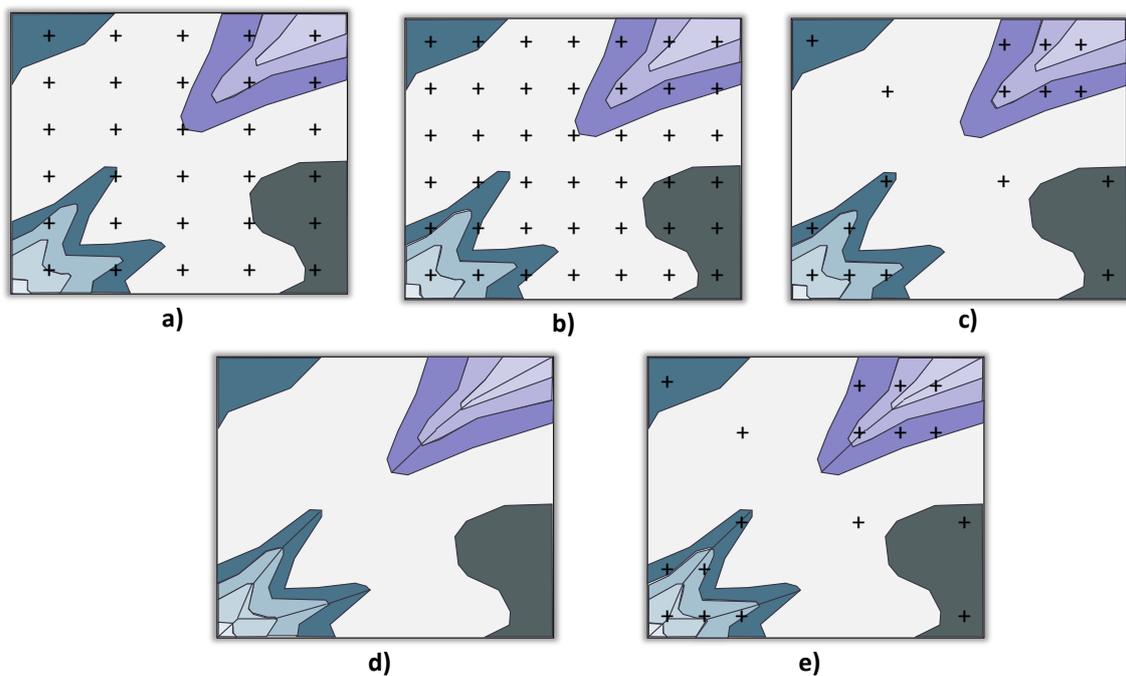


Figura 8.3 - Técnicas de recolha de amostras: (a) padrão regular de amostras; (b) rede regular; (c) progressiva; (d) seletiva; (e) composta.

As amostras regulares podem ser denominadas de grelhas, devido à utilização de uma distância constante entre amostras, sendo deveras importante determinar o espaçamento ótimo. Como vantagem apresentam o facto de poderem ser obtidas de forma semiautomática ou automática e como desvantagem pode-se apontar a captação de

demasiadas amostras em objetos de grandes dimensões e opostamente, de poucas em objetos diminutos.

Por outro lado, nas amostras progressivas a densidade de amostras recolhidas adapta-se às características complexas dos objetos. O processo tem início com a criação de uma grelha de espaçamento largo e a posterior análise da exactidão obtida. Sempre que se revele necessário a densidade da grelha é revista recursivamente de modo a atingir os parâmetros requeridos.

Por fim, as amostras seletivas capturam seletivamente as quebras de homogeneidade espacial. Este método pode ser combinado com o das amostras progressivas, passando a denominar-se de amostra composta. Este método composto usa as amostras seletivas para retratar mudanças abruptas e as amostras progressivas para representar a restante superfície. A vantagem deste sistema é manter a mudança recursiva das amostras progressivas a um nível mínimo e representar as discontinuidades espaciais com exactidão. O fator menos positivo corresponde à necessidade de intervenção humana, pelo que este método apenas pode ser parcialmente automatizado. Pode-se simplificar esta análise em dois métodos principais de amostragem:

- ◆ **Amostragem aleatória simples** – Este método reduz o efeito de autocorrelação de píxeis ou objetos vizinhos (Richards e Jia, 2006). Porém, a amostragem aleatória simples levanta um problema, pois é ponderada pela área, *i.e.*, poderá amostrar por defeito classes que sejam pouco representativas na área total do mapa, a não ser que a dimensão da amostra seja suficientemente grande para abranger todas as classes.
- ◆ **Amostragem aleatória estratificada** – é definido um número de amostras a seleccionar em cada estrato ou classe de uso do solo, para além de reduzir o efeito de autocorrelação espacial, garante que cada classe seja amostrada (Stehman, 2001; Jensen, 2004; Richards e Jia, 2006; Congalton e Green, 2009). Porém, apesar de ser adequado para seleccionar o número total de objetos para a amostra, este método não foi criado para seleccionar a dimensão de uma amostra (em Jensen, 1996).

O cuidado na escolha dos pontos e a quantidade de dados amostrados estão diretamente relacionados com a qualidade do produto final de uma aplicação sobre o

modelo, *i.e.*, a dimensão da amostra deve ser suficiente para uma avaliação significativa e coerente. Para aplicações onde se requer um grau de realismo maior, a quantidade de pontos amostrados, bem como o cuidado na escolha desses pontos, *i.e.*, a qualidade dos dados, são decisivos.

De uma forma geral, “quanto maior é a amostra, maior é a confiança dos resultados da avaliação da exatidão” (Costa, 2008). Quanto maior a quantidade de pontos representantes da superfície real, maior será o esforço computacional para que estes sejam armazenados, recuperados, processados, até que se alcance o produto final da aplicação.

No que respeita à dimensão da amostra, não existem regras muito bem definidas. Por um lado, a dimensão da amostra deve ser suficientemente grande para permitir uma análise com significado estatístico. Mas, por outro lado, a recolha de dados de referência para os pontos de validação é um processo moroso e oneroso. Assim, deve-se manter a dimensão da amostra num mínimo que garanta o valor estatístico dos resultados (Congalton e Green, 2009). A dimensão da amostra, em muitos estudos, tem sido estimada com uma função binomial:

$$n_h = \frac{p_h(1-p_h)}{\sigma_h^2}, \quad (8.1)$$

onde n_h é o número de pontos da amostra, p_h é uma taxa de erro estimada e σ_h^2 é o desvio padrão aceite para a estimativa do percentagem de pontos incorretamente classificados.

Esta forma de estimar a dimensão da amostra, quando aplicada a uma amostragem por estratos, pode ter o inconveniente de, em estratos com uma área pequena, o número de pontos ser extremamente grande. Por essa razão, pode-se estabelecer um número máximo de pontos por unidade de área, *e.g.*, 2 pontos por km².

Mas, como já se referiu, não existem formas *standard* de validação, e a utilização de modelos binomiais para estimar a dimensão da amostra tem sido criticada por alguns autores por não se adaptar à natureza das matrizes de confusão. Recentemente, a utilização de distribuição multinomial tem sido mais recomendada (Congalton e Green, 1999). Isto deve-se principalmente ao facto das técnicas “clássicas” para a determinação de número de amostras, *i.e.*, baseadas na distribuição binomial, não terem sido concebidas para serem aplicadas na avaliação da exatidão temática.

Devido ao elevado número de objetos envolvidos nos dados de deteção remota, os métodos de amostragem tradicionais não são aplicáveis. Para tal, como já foi referido, “(...) deverá ser feito um balanço entre o que é estaticamente correto e o que é realmente exequível” (Oliveira,2011).

8.2.2. Criação da amostra para a avaliação da exatidão

Como mencionado no capítulo anterior, quando existe um número muito elevado de objetos, estes não podem ser analisados e avaliados na sua totalidade. Desta forma, “(...) é preciso estudar estes objetos através de subconjuntos representativos, as amostras” (Abreu, 2006).

A seleção do conjunto das unidades de amostra realizou-se através de uma amostragem aleatória estratificada por classe de ocupação do solo a partir de um mapa preliminar obtido durante os testes. Esta opção deveu-se ao facto desta estratégia de amostragem garantir que todas as classes são amostradas (Costa, 2008).

Através do *software* ArcMap® 10.2, foram recolhidos pontos de forma aleatória para evitar efeitos de autocorrelação espacial, aumentando assim a probabilidade de que a amostra seja representativa de todas as variações que as diferentes classes apresentam na imagem (Oliveira, 2011). Uma vez que cada ponto se situa num objeto de imagem (não pode haver mais do que 1 ponto no mesmo objeto), este representa inevitavelmente uma classe de ocupação do solo. Assim, foi recolhido para cada imagem, um total de 210 pontos, *i.e.*, 30 pontos por cada classe de ocupação do solo.

O processo de amostragem foi comum para todas as imagens classificadas, tendo sido sempre recolhido o mesmo número de pontos, porém com localizações diferentes devido à aleatoriedade. Seria igualmente mais indicado que, para cada cartografia de ocupação do solo realizada, se procedesse à recolha das unidades de amostra de validação com a mesma localização. Porém, se tivessem sido utilizados os mesmos pontos nas 8 imagens, não se registava o mesmo número de unidades de amostra em cada classe devido à dinâmica espaço-temporal da ocupação do solo. Assim, tal como em Costa 2008, “(...) a adoção da mesma estratificação proveniente do mapa preliminar na validação de todos os resultados foi uma solução de compromisso que se considerou adequada.”

Seria indicado recolher 100 unidades de amostragem por estrato visto que este número de observações por classe garante que a estimativa da exatidão global do mapa e específica da classe, tenha uma margem de erro absoluta absoluta nunca superior a 10%, para um nível de significância de 0,05 (Stehman, 2001).

No entanto, a recolha de 100 observações por classe seria um processo moroso, não compatível com o processo de desenvolvimento dos testes de classificação. Assim, definiu-se um compromisso entre a precisão da estimativa dos índices de qualidade e a rapidez do processo, ao recolher 30 observações por classe, o que garante uma margem de erro absoluta inferior a 18,26%.

8.2.3. Recolha de dados para cada amostra

Após a seleção das unidades de amostra de validação, procede-se à comparação entre os elementos de ocupação do solo classificados e o que realmente se encontra no território. Para tal, é necessário recorrer a diversas fontes de dados que nos permitem retirar essa informação. Nestes casos, os dados de referência são geralmente obtidos através da interpretação visual de imagens com uma maior resolução espacial que os dados utilizados na produção do mapa de classificação tais como: imagens de satélite, imagens aéreas, verificação no terreno (Biging *et al.*, 1998; Caetano *et al.*, 2002) e interpretação visual de orto-imagens.

Cada passo “deve ser rigorosamente planeado e implementado” (Congalton e Green, 2009). Para tal, é fundamental a recolha de dois tipos de informação para que o processo de amostragem seja bem aplicado:

- ◆ **Dados de referência** – a posição ou o rótulo da classe do local de avaliação da exatidão, o qual é derivado a partir dos dados que são considerados corretos;
- ◆ **Dados a avaliar** – a posição ou rótulo da classe do local de avaliação da exatidão, o qual é derivado a partir do mapa ou da imagem a ser avaliada.

Após a realização do processo de amostragem, foi feita uma interpretação visual aos objetos então selecionados, com o auxílio de imagens de alta resolução (*Google Earth*). Foram atribuídos dois códigos a cada unidade de amostra, um referente à classe de ocupação do solo assumida nos mapas classificados, e o outro, referente à classe de ocupação do solo real.

A numeração dos códigos utilizados, corresponde aos designados na nomenclatura de ocupação do solo do CLC (Tabela 8.1).

Tabela 8.1 - Codificação das classes de ocupação do solo

Código	Designação da classe
1	Territórios artificializados
2	Áreas agrícolas e agroflorestais
3	Florestas e meios naturais e seminaturais
33	Zonas descobertas e com pouca vegetação
42	Zonas húmidas litorais
51	Águas interiores
52	Águas marinhas e costeiras

Uma unidade de amostra considera-se bem classificada, quando o código referente ao mapa produzido corresponde ao código atribuído através da interpretação visual da ocupação do solo daquela imagem.

Por conseguinte, procede-se à manipulação da informação resultante das unidades de amostra, tendo sido construídas as matrizes de confusão para cada mapa de classificação e consequentemente calculadas as medidas de exatidão.

As medidas de exatidão foram calculadas em dois níveis: um referente a cada uma das imagens classificadas, e o outro referente a cada uma das classes extraídas. Com esta desagregação, é possível verificar não apenas se as classes apresentaram bons resultados aquando a sua classificação, mas também quais as imagens que suportaram melhor o algoritmo. É de relembrar, que o objetivo principal desta dissertação, passa por demonstrar a replicabilidade de um algoritmo de classificação.

8.2.4. Análise dos resultados

Depois de terminado o processo de amostragem dá-se início ao cálculo dos índices de avaliação da qualidade da classificação. Os métodos utilizados para estimar a exatidão dos mapas obtidos após a classificação têm como ponto de partida a construção de uma matriz de confusão. Esta matriz apresenta a distribuição de percentagem dos objetos classificados de forma correta ou errónea. (Congalton, 1991). Segundo Martins (2012) a matriz de confusão tem pelo menos 3 propriedades úteis:

- i. Oferece dados que permitem o ajuste das áreas das classes obtidas por algum tipo de classificação;
- ii. Possibilita o cálculo de parâmetros de exatidão geral da classificação;
- iii. Permite a identificação de erros específicos que afetam cada uma das classes extraídas.

A matriz de confusão é a técnica mais utilizada para proceder à avaliação da exatidão temática (Lu e Weng, 2007). A matriz é formada por um arranjo quadrado de números dispostos em linhas e colunas que expressam o número de unidades de amostras de uma classe do mapa de ocupação do solo, em comparação com a classe atual verificada no campo (Congalton, 1991). Nela encontra-se descrito o padrão da distribuição de cada uma das classes de ocupação do solo referente à informação de referência através "(...) da visualização das observações na diagonal da matriz (concordância entre o mapa e a informação de referência) e fora da diagonal (confusão entre classes)" (Costa, 2008).

A Figura 8.4 mostra a estrutura de uma matriz de confusão de um hipotético mapa de ocupação do solo, em que n_{ij} corresponde ao número amostras de validação observadas na classe i do mapa e que corresponde à classe i na informação de referência, n_{i+} ao total de amostras de validação classificadas no mapa com a classe i , e n_{+i} ao total de amostras de validação observadas pertencentes à classe i .

		Informação de referência				Total
		1	2	...	q	
Mapa	1	n_{11}	n_{12}	...	n_{1q}	n_{1+}
	2	n_{21}	n_{22}	...	n_{2q}	n_{2+}
	⋮	⋮	⋮	⋮	⋮	⋮
	q	n_{q1}	n_{q2}	...	n_{qq}	n_{q+}
	Total	n_{+1}	n_{+2}	...	n_{+q}	n

Figura 8.4 - Matriz de confusão com q classes de ocupação do solo (adaptado de Costa, 2008)

A informação que se pode extrair da matriz de confusão permite calcular, entre outras, seis medidas:

- ◆ **Exatidão global da amostra (EG)** - A exatidão global (Tabela 8.2) da amostra é a soma dos dados da diagonal da matriz de confusão, divididos pelo número total de objetos da amostra. É comum calcular a média das percentagens de classificações corretas e assumi-la como sendo a exatidão global. Porém, um índice mais correto deverá ponderar a média segundo as áreas ocupadas por cada classe do mapa (Richards e Jia, 2006);

Tabela 8.2 - Medidas globais de fiabilidade e respetivas equações

Medidas	Equação	
Exatidão global	$EG = \frac{\sum x_i}{n} \cdot 100$	x_i = elementos na diagonal n = total de amostras
Exatidão do produtor	$EP_j = \frac{x_{jj}}{n_{i+}}$	x_{jj} = elementos na diagonal n_{i+} = total de amostras
Exatidão do utilizador	$EU_j = \frac{x_{jj}}{n_{i+1}}$	n_{i+1} = total de amostras n = total de amostras
Coefficiente de concordância <i>Kappa</i>	$K = \frac{n \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} x_{+i}}{n^2 - \sum_{i=1}^c x_{i+} x_{+i}}$	r = número de linhas da matriz da confusão x_{ii} = observações na linha i e coluna i x_{i+} = total marginal da linha i x_{+i} = total marginal da coluna i

- ◆ **Exatidão do produtor (EP) das classes** - A exatidão do produtor da classe (x), traduz a probabilidade de um objeto verdadeiro da classe (x) estar realmente representado na cartografia por (x). Resulta do quociente entre o número de elementos corretamente classificados em cada classe e o número de objetos de treino utilizados nessa classe (total da coluna);
- ◆ **Exatidão do utilizador (EU) das classes** - A exatidão do utilizador da classe (x), traduz a probabilidade de um objeto etiquetado como classe (x) pertencer realmente à classe (x). Resulta da divisão entre o número de objetos corretamente classificados pelo número total de objetos que foram classificados nessa classe (total da linha);
- ◆ **Erros de omissão (EO) das classes** - Os erros de omissão são um complemento do EP, na medida em que traduz os seus erros associados. Os EO da classe (x) correspondem aos objetos pertencente à classe (x) mas não foram

identificados como tal pelo utilizador, *i.e.*, encontram-se omitidos na imagem classificada, na classe (y);

- ◆ **Erros de comissão (EC) das classes** - Os erros de comissão são um complemento do EU, na medida em que traduz os seus erros associados. Os EC da classe (x) correspondem aos objetos que foram identificados como sendo da classe (x) mas pertencem à classe (y).
- ◆ **Coefficiente de concordância *Kappa* (K), da globalidade da legenda e por classe individual** - O coeficiente de concordância *Kappa* é uma técnica multivariada discreta desenvolvida por Cohen em 1960. Congalton (1991) defende que a utilização deste coeficiente permite avaliar satisfatoriamente toda a imagem classificada, porque considera nos seus cálculos toda a matriz de confusão. Na Tabela 8.3 é apresentada a classificação dada a um mapa consoante a sua qualidade através do coeficiente de concordância *Kappa*.

Tabela 8.3 - Qualidade da classificação dos valores do coeficiente de concordância *Kappa* (adaptado de Martins, 2012)

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

8.3. Avaliação da exatidão temática por imagem

A avaliação da exatidão temática constitui a última etapa metodológica deste trabalho. É nesta fase que é realizada uma avaliação à qualidade da classificação de ocupação do solo obtida através do algoritmo criado. Esta avaliação, apenas compreendeu as classes de ocupação do solo, tendo sido excluída a classe referentes às ‘nuvens e respetivas sombras’. É de lembrar, que a classificação desses objetos foi necessária porque a sua presença prejudicava a extração das classes pretendidas.

Para a avaliação da cartografia de ocupação do solo realizada para as 8 imagens em estudo, optou-se por calcular o índice de exatidão do produtor e utilizador, bem como o coeficiente de concordância *Kappa*.

Com o auxílio da Tabela 8.4, é possível concluir que as imagens que apresentam uma classificação com melhores resultados e com erros de exatidão mais reduzidos, correspondem a imagens do conjunto de treino. Em pormenor, a imagem de 22 de julho de 2013, é a que apresenta o maior número de observações bem classificadas (207), de seguida a imagem de 27 de novembro de 2013 com 206 observações, e por fim a imagem de 23 de agosto de 2013 com 204 observações. Em relação à percentagem de exatidão do utilizador, mantém-se a mesma ordem de imagens anteriormente mencionada. No entanto, na percentagem de exatidão do produtor, a imagem com valores superiores é a de 27 de novembro de 2013 (99,63%), de seguida a de 22 de julho de 2013 (98,86%) e por fim, a de 23 de agosto de 2013 (97,36%).

Tabela 8.4 - Exatidão do utilizador e produtor (%) e coeficiente de concordância *Kappa* das imagens de treino e de teste

	Imagens			N.º Observações	% Exatidão		Coeficiente de concordância <i>Kappa</i>
					Utilizador	Produtor	
Treino	22	julho	2013	207	98,57	98,86	0,983
	23	agosto	2013	204	97,14	97,36	0,967
	10	outubro	2013	203	96,67	96,84	0,961
	27	novembro	2013	206	98,10	99,63	0,978
Teste	29	outubro	2014	203	96,67	96,88	0,961
	11	novembro	2013	201	95,71	96,00	0,961
	09	julho	2014	199	94,76	94,96	0,939
	08	setembro	2013	203	96,67	96,87	0,950

Como seria de esperar, as imagens do conjunto de teste apresentam resultados ligeiramente inferiores, em comparação às restantes imagens, porque estas foram classificadas através da aplicação do algoritmo e não tiveram qualquer intervenção do produtor, *i.e.*, foram classificadas (semi)automaticamente. Em relação ao coeficiente de concordância *Kappa*, é de notar que, segundo a Tabela 9.2, todas as classificações apresentam uma qualidade catalogável como excelente, sendo que o valor de *Kappa* mais reduzido e de 0,939 (09 de julho de 2014) e o mais elevado de 0,983 (22 julho de 2013).

Por fim, pode-se afirmar que todas as imagens apresentaram valores bastante satisfatórios, apesar da multitemporalidade implicar uma ligeira diminuição da qualidade de classificação das imagens.

8.4. Avaliação da exatidão temática por classe

Todas as classes de ocupação do solo foram avaliadas *per se*. Este processo deve ser sempre efetuado uma vez que as medidas globais podem escamotear grandes variações intraclasse. As classes 'Águas interiores' e 'Águas marinhas e costeiras' foram logo *a priori* excluídas deste processo, na medida em que não houve nenhuma observação mal classificada. Desta forma não foi necessário apresentar os valores destas classes na Tabela 8.5 e na Tabela 8.6.

Tabela 8.5 - Erros de comissão (%) das classes de ocupação do solo nas imagens de treino e de teste

				Erros de Comissão (%)				
Imagens				Territórios artificializados	Áreas agrícolas e agroflorestais	Florestas e meios naturais e seminaturais	Zonas descobertas e com pouca vegetação	Zonas húmidas litorais
Treino	22	julho	2013	0	0	0,48	0,95	0
	23	agosto	2013	2,86	0	0	0	0
	10	outubro	2013	0,95	0,48	1,43	0,48	0
	27	novembro	2013	0,95	0,00	0,48	0,48	0
Teste	29	outubro	2014	0,95	0,95	0,48	0,95	0
	11	novembro	2013	2,38	0	0,48	0,95	0,48
	09	julho	2014	2,38	0,95	0,95	0,95	0
	08	setembro	2013	1,90	0,48	0,48	0,48	0
Valor médio				1,55	0,36	0,60	0,66	0,06

A Tabela 8.5 apresenta os EC, *i.e.*, a percentagem de observações que foram classificadas como pertencentes a uma classe, mas que na realidade são relativas a outra classe. Analisando a tabela, é possível perceber que existe uma classe de ocupação do solo com grande destaque, 'Territórios artificializados'. Esta classe apresenta um valor médio de 1,55% de ocorrências falsamente atribuídas. Esta situação verifica-se em maior número na imagem de 23 de agosto de 2013 e apenas na imagem de 22 de julho de 2013 não são verificados erros de comissão. Em seguida, destacam-se as classes, 'Zonas descobertas e com

pouca vegetação’, e ‘Florestas e meios naturais e seminaturais’, com valores médios de erros de comissão de 0,66 e 0,60, respetivamente. Em contraste, a classe ‘Zonas húmidas’ e *litorais*, apresenta erros de comissão na imagem de 11 de novembro de 2013 de apenas 0,48%.

Os erros de omissão (Tabela 8.6) dizem respeito às observações pertencentes a uma classe, mas que não foram classificados como tal. Nesta análise, verifica-se que a classe ‘Zonas descobertas e com pouca vegetação’ apresenta os valores mais elevados, nomeadamente, 3,33% na imagem de 9 de julho de 2014 e 2,86% na imagem de 23 de agosto de 2013. De seguida, destaca-se a classe ‘Territórios artificializados’ com 1,43% na imagem de 11 de novembro de 2013. Em contraste, verifica-se que existe uma classe que não apresenta erros de omissão, nomeadamente a classe das ‘Zonas húmidas litorais’.

Tabela 8.6 - Erros de omissão (%) das classes de ocupação do solo nas imagens de treino e de teste

				Erros de Omissão (%)				
Imagens				Territórios artificializados	Áreas agrícolas e agroflorestais	Florestas e meios naturais e seminaturais	Zonas descobertas e com pouca vegetação	Zonas húmidas litorais
Treino	22	julho	2013	0,95	0	0	0,48	0
	23	agosto	2013	0	0	0	2,86	0
	10	outubro	2013	0,48	0,95	0	1,90	0
	27	novembro	2013	0,48	0,48	0	0,95	0
Teste	29	outubro	2014	0,95	0	0	2,38	0
	11	novembro	2013	1,43	0,48	0	2,38	0
	09	julho	2014	0,95	0	0,95	3,33	0
	08	setembro	2013	0,48	0,48	0,48	1,90	0
Valor médio				0,71	0,30	0,18	2,02	0

Em relação aos erros de omissão e comissão, verifica-se que o conjunto de imagens de teste apresenta, como é expectável, um número mais elevado de erros. Porém, estes continuam a não ser significativos no sentido em que não comprometem a qualidade da cartografia.

A matriz de confusão permite perceber se existe alguma relação entre as classes, no que diz respeito às observações omitidas e cometidas. Na Tabela 8.7 é possível perceber em que classes as observações omitidas foram classificadas e que classes estão a incluir observações que não lhes pertencem. Por exemplo, a classe ‘Territórios artificializados’

apresenta 214 observações bem classificadas. Porém, inclui também 26 observações que na verdade pertencem à classe ‘Zonas descobertas e com pouca vegetação’ (valores em linha). Por conseguinte, existem 11 observações classificadas como ‘Zonas descobertas e com pouca vegetação’, e uma como ‘Zonas húmidas litorais’ que não foram devidamente classificadas, *i.e.*, pertencem à classe ‘Territórios artificializados’.

Tabela 8.7 - Contagem do número de observações totais de validação omitidas e incluídas para as imagens de treino e de teste

Classes	Territórios artificializados	Áreas agrícolas e agroflorestais	Florestas e meios naturais e seminaturais	Zonas descobertas e com pouca vegetação	Zonas húmidas litorais	Total Incluído
Territórios artificializados	214	0	0	26	0	26
Áreas agrícolas e agroflorestais	0	234	3	3	0	6
Florestas e meios naturais e seminaturais	0	1	230	4	0	5
Zonas descobertas e com pouca vegetação	11	0	0	229	0	11
Zonas húmidas litorais	1	0	0	0	239	1
Total omitido	12	1	3	33	0	98

Concluindo, após a análise das Tabelas 8.5, 8.6 e 8.7 pode-se inferir que as classes com erros mais elevados foram os ‘Territórios artificializados’, por incluir observações de outras classes, e a as ‘Zonas descobertas e com pouca vegetação’, por omitir muitas observações, sendo que existe uma relação entre as mesmas, na medida em que a “troca de ocorrências” verifica-se maioritariamente entre estas classes. O coeficiente de concordância Kappa (Figura 5.5) permite reforçar as conclusões retiradas das tabelas de EC e de EO.

O índice *Kappa* permite ilustrar quais as classes que apresentam melhores ou piores desempenhos na classificação e em que imagens é que eles ocorrem. Neste contexto, destaca-se fortemente a classe ‘Territórios artificializados’ com um resultado menos animador na imagem de 23 de agosto de 2014. Em contrapartida, as classes ‘Águas marinhas

e costeiras’, ‘Águas interiores’ e ‘Zonas Húmidas Litorais’ (exceto na imagem de 11 de novembro de 2013) apresentam resultados a 100%, não possuindo erros na sua classificação. No entanto, deve-se sublinhar que a avaliação foi realizada através de uma amostra de objetos e não de toda a imagem, *i.e.*, podem existir objetos mal classificados, mas que não foram incluídos na amostra de validação.

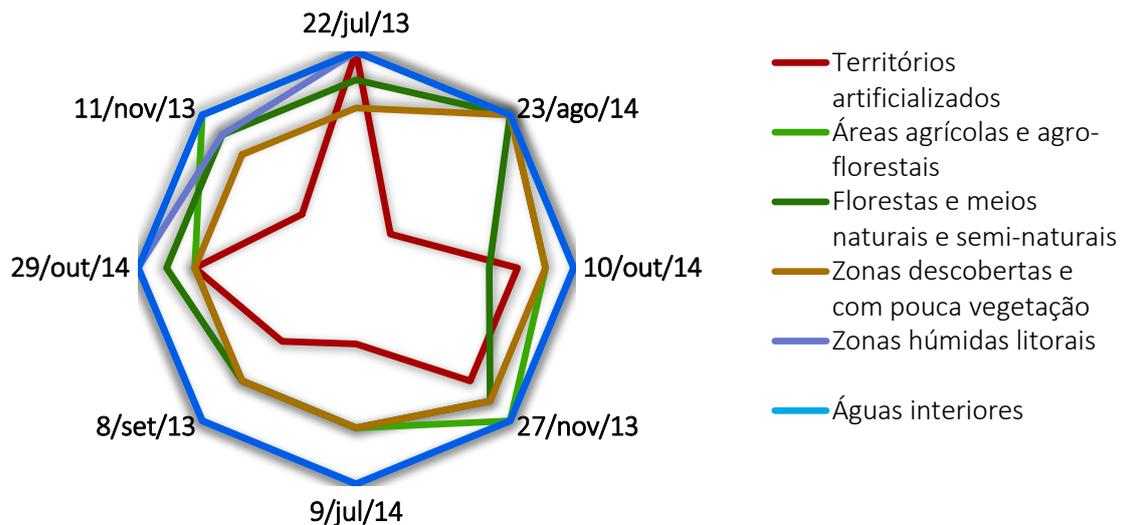


Figura 8.5 - Coeficiente de concordância *Kappa* de cada imagem classificada por classe de ocupação do solo

8.5. Avaliação da exatidão temática do teste de sensibilidade à metodologia de classificação multitemporal

Para avaliar a sensibilidade do método de classificação (semi)automático desenvolvido nesta dissertação, bem como a qualidade das classificações resultantes do teste de projeção, foram aplicadas ao conjunto de teste todas as medidas de fiabilidade apuradas para o conjunto de treino. Para este exercício a atenção centrou-se em quatro classes: ‘Territórios artificializados’, ‘Áreas agrícolas e agroflorestais’, ‘Florestas e meios naturais e seminaturais’ e ‘Zonas descobertas e com pouca vegetação’.

Relativamente à exatidão do utilizador e produtor, e coeficiente de concordância *Kappa*, os melhores resultados foram obtidos com a utilização dos limiares da imagem de 23 de agosto de 2013. Numa análise mais atenta pode-se constatar, segundo a Tabela 8.8, que a

imagem de 9 de julho de 2014 classificada com os limiares de 10 de outubro de 2013 apresenta um resultado tido como muito bom enquanto a classificação com os limiares de 23 de agosto de 2013 tem uma qualidade considerada excelente.

Tabela 8.8 - Exatidão do utilizador e produtor (%) e coeficiente de concordância *Kappa* para a imagem do teste de projeção

Imagem 09 julho 2014	N.º Observações	% Exatidão		Coeficiente de concordância <i>Kappa</i>	
		Utilizador	Produtor		
Limiar	23 agosto 2013	147	81,7	85,19	0,80
	10 outubro 2013	125	69,4	75,87	0,67

Relativamente aos erros de comissão (Tabela 8.9), verifica-se facilmente que os valores aumentaram em todas as classes e em ambas as imagens. A classe ‘Territórios artificializados’ continua a ser a classe com erros mais elevados (9,72%), porém a segunda classe a destacar refere-se às ‘Áreas agrícolas e agroflorestais’ (6,39%), com maior peso na imagem classificada com os limiares de 10 de outubro de 2013 (10,56%).

Ao contrário do que se verificou anteriormente (*cf.* secção 8.4), a classe ‘Zonas descobertas e com pouca vegetação’ é a classe que apresenta erros de comissão menores.

Tabela 8.9 - Erros de comissão (%) para a imagem do teste de projeção

Erros de Comissão (%)							
Imagem 09 julho 2014			Territórios artificializados	Áreas agrícolas e agroflorestais	Florestas e meios naturais e seminaturais	Zonas descobertas e com pouca vegetação	
Limiar	23	agosto	2013	9,44	2,22	4,44	2,22
	10	outubro	2013	10,00	10,56	6,67	3,33
Valor médio				9,72	6,39	5,56	2,78

Ao analisar a Tabela 8.10 referente aos EO, verifica-se que a classe ‘Zonas descobertas e com pouca vegetação’ é a que apresenta os valores mais elevados, nomeadamente, 20% na imagem com os limiares de 10 de outubro de 2013 e 12,78% na imagem com os limiares de 23 de agosto de 2013. De seguida, destaca-se a classe ‘Florestas e meios naturais e seminaturais’ com 5% de valor médio. Opostamente, verifica-se que existe mais uma classe que não apresenta erros de omissão, nomeadamente a classe das ‘Zonas húmidas litorais’.

Tabela 8.10 - Erros de omissão (%) para as imagens do teste de projeção

				Erros de Omissão (%)			
Imagem 09 Julho 2014				Territórios artificializados	Áreas agrícolas e agroflorestais	Florestas e meios naturais e seminaturais	Zonas descobertas e com pouca vegetação
Limiar	23	agosto	2013	1,11	1,11	3,33	12,78
	10	outubro	2013	2,78	1,11	6,67	20,00
Valor médio				1,94	1,11	5,00	16,39

Tendo em atenção os erros de omissão e comissão, verifica-se, como seria previsível, que o conjunto de imagens de teste apresenta um número mais elevado de incorreções. Porém, estes erros continuam a não ser significativos pois não comprometem a qualidade da cartografia. Na Tabela 8.11 é possível perceber a dinâmica entre as classes em que as observações omitidas foram classificadas e as classes que estão a incluir observações incorretamente.

Neste contexto, destaca-se a classe 'Territórios artificializados' que apresenta 25 observações bem classificadas. Porém, há 35 observações que se encontram incluídas nesta classe, mas na verdade pertencem à classe 'Zonas descobertas e com pouca vegetação'. Deve-se também destacar a classe 'Zonas descobertas e com pouca vegetação', visto que é a que possui o maior número de observações omitidas (59), estando distribuídas pelos 'Territórios artificializados' (35), pelas áreas 'Agricultoras e agroflorestais' (8) e pelas 'Florestas e meios naturais e seminaturais' (16).

Após uma análise geral das tabelas relativas à avaliação do teste de sensibilidade (Tabelas 8.8, 8.9, 8.10 e 8.11) verifica-se que existe um ligeiro aumento dos erros em todas as classes. Ainda assim, as suas posições relativas mantêm-se, observando-se que as classes 'Territórios artificializados' e 'Zonas descobertas e com pouca vegetação' continuam a possuir uma forte associação, na medida em que os erros a elas associados encontram-se inter-relacionados.

Tabela 8.11 - Contagem do número de amostras totais de validação omitidas e incluídas para o teste de projeção

Classes	Territórios artificializados	Áreas agrícolas e agroflorestais	Florestas e meios naturais e seminaturais	Zonas descobertas e com pouca vegetação	Total Incluído
Territórios artificializados	25	0	0	35	35
Áreas agrícolas e agroflorestais	0	37	15	8	23
Florestas e meios naturais e seminaturais	0	4	42	16	20
Zonas descobertas e com pouca vegetação	7	0	3	50	10
Total omitido	7	4	18	59	176

Nesta avaliação, também se constata um aumento dos erros entre as classes ‘Áreas agrícolas e agroflorestais’ e ‘Florestas e meios naturais e seminaturais’. No cerne do problema está o facto de as ‘Áreas agrícolas e agroflorestais’ incluírem muitas observações da classe ‘Florestas e meios naturais e seminaturais’ (15) e algumas da classe ‘Zonas descobertas e com pouca vegetação’ (8). Por conseguinte, a classe ‘Florestas e meios naturais e seminaturais’ também apresenta um grande número de observações que deveriam pertencer à classe ‘Zonas descobertas e com pouca vegetação’ (16). Concluindo, a classe ‘Zonas descobertas e com pouca vegetação’, omite cerca de 59 observações distribuídas por todas as classes, mas maioritariamente concentradas na classe ‘Territórios artificializados’.

Comparando os resultados entre as imagens cujos limiares foram calculados (*i.e.*, treino), e as imagens cujos limiares foram selecionados das imagens de treino (*i.e.*, teste), verificou-se o previsível o aumento dos erros de classificação e a consequente deterioração da qualidade da cartografia produzida. Este resultado deve-se ao facto de não serem utilizados limiares definidos específicos para as imagens de teste. Ao nível das imagens, a classificação de 10 de outubro de 2014 apresentou resultados menos satisfatórios que a de 23 de agosto de 2014 porque a diferença relativamente aos limiares apurados era superior.

Capítulo 9 - Considerações finais

A partir da ampla revisão da literatura efetuada no âmbito desta dissertação, pode-se concluir que a OBIA representa uma importante tendência no contexto da detecção remota e da geoinformação.

O aparecimento desta abordagem coexistiu com as necessidades crescentes de uma maior resolução espacial e a existência de grandes quantidades de dados geoespaciais que exigiam tratamento dentro de um prazo muito específico. Paralelamente, a sua tendência inicial técnico-positivista (Burnett e Blaschke, 2002; Lang, 2005, 2008) tem gerado elevados níveis de interesse sobre questões ontológicas, epistemológicas e metodológicas de escala, manipulação de dados multi-escala e fusão de dados.

A OBIA levou a uma redescoberta do pensamento original sobre a construção do espaço, sobre a cognição espacial e sobre a decomposição de sistemas (Koestler, 1967; Simon, 1973; Wu e Loucks, 1995). É um fato que a mente humana não é projetada para lidar com o caos contínuo em grande escala, nem funciona de forma ideal quando lida com a uniformidade perfeita em grande escala (Cutter *et al.*, 2002). O grande conjunto de soluções técnicas interligadas com uma infinidade de informações geoespaciais exige que haja pluralidade de soluções. Hoje, a OBIA é uma metodologia sólida no contexto do processamento avançado de dados.

Continua em aberto a questão de se a OBIA é, ou não, um novo paradigma. No entanto, aparte esses considerandos, é inegável que o *software* de OBIA, e principalmente o eCognition®, foi muito bem-sucedido no mercado e desencadeou investimentos na indústria e na academia. O eCognition® oferece um novo potencial e preenche critérios decisivos, incluindo importantes aspetos multifonte, multimétodo e multi-escala. Além disso, o eCognition® caracteriza-se pelos poderosos algoritmos de segmentação de que dispõe atualmente e a possibilidade de modelação e classificação cruzadas e hierárquicas.

Uma das questões mais prementes que se tem colocado no contexto da investigação em OBIA em geral, e na utilização do eCognition® em particular, é a da reprodutibilidade metodológica. Walker e Blaschke (2008) e Schöpfer e Möller (2006) demonstraram que a reprodutibilidade direta dos métodos OBIA é viável. No entanto, permanece a questão da

designada reprodutibilidade indireta ou independente, *e.g.* identificação de um objeto inalterado entre duas datas de forma igual nas duas imagens, como um dos principais focos da investigação em OBIA.

Foi exatamente a pertinência deste último ponto, o da reprodutibilidade indireta, que serviu de alicerces ao desenvolvimento desta dissertação. Assim, no seguimento da investigação em cursos no LNEC sobre métodos para automatização do processo de identificação dos limiares de corte de funções para a classificação temática de imagens SAR, optou-se por desenvolver uma metodologia análoga passível de ser aplicada a imagens Landsat 8. Esta abordagem visava o estabelecimento de um algoritmo de classificação que pudesse explorar a aplicação da OBIA a dados de média/alta resolução de forma a estabelecer uma metodologia eficaz de classificação de ocupação do solo a nível regional que seja reprodutível em diferentes contextos temporais com uma intervenção mínima por parte do operador.

Numa avaliação geral, entende-se, quando existir um catálogo de regras de decisão possíveis de serem transmissíveis ou adaptáveis a diferentes áreas de estudo e diferentes tipos de dados, será possível almejar uma cartografia automática de ocupação do solo. Sem a formalização e sistematização de um conjunto de regras de decisão, as operações apresentam ainda uma forte dependência da intervenção e decisão do utilizador. A principal vantagem deste tipo de abordagem resulta também numa particularidade que se reflete na complexidade do processo. Contudo, antevendo a determinação de regras de decisão transferíveis e iniciando a modelação da sequência de procedimentos através da exportação do algoritmo de classificação, pode-se direcionar esforços para a simplificação e classificação automática de imagens.

A possibilidade de poder dispor de um inventário multitemporal de ocupação do solo é tão mais importante quanto a celeridade a que ocorrem transformações sobre o território. A par destas mudanças, a evolução das tecnologias e das técnicas tem permitido recorrer a processos automáticos e semiautomáticos de análise e avaliação, quer qualitativa, quer quantitativa (com rigor e precisão,) da dinâmica de alterações da ocupação do solo.

Deste modo assegura-se um processo de produção de cartografia de ocupação do solo, célere e pouco oneroso, possibilitando a obtenção de informação basilar para os processos de elaboração e/ou validação das ações de planeamento e ordenamento do

território. Efetivamente, a importância da informação obtida pela aplicação da OBIA constitui uma ajuda preciosa à definição e ou redefinição de modelos de organização do território, de combate aquilo que já são problemas crónicos no quadro do ordenamento do território e do desenvolvimento do país.

Analisando especificamente o processo de classificação da ocupação do solo, verificou-se uma adequabilidade satisfatória da nomenclatura hierárquica ao processo de classificação de dados, quer quanto ao número quer quanto ao tipo de classes. O primeiro nível da legenda CLC foi perfeitamente atingido, conseguindo-se mesmo atingir em três casos o segundo nível de desagregação. Haveria a possibilidade de optar por um uso generalizado do nível 2 do CLC mas esta opção implicaria uma necessária redução da exatidão da classificação, podendo comprometer a sua utilização em contexto operacional.

Importa ressaltar que os objetivos iniciais não enquadravam a intenção de produzir um elevado número de classes. Procuravam sim, perceber se a replicação do algoritmo criado apresentava resultados promissores e, por conseguinte, o seu reconhecimento como método de classificação semiautomático.

A elaboração do algoritmo propriamente dito, deparou-se com algumas particularidades intrínsecas às características do Landsat 8, nomeadamente no que concerne à sua resolução espacial. Verdadeiramente, a dimensão do píxel de 900m², correspondendo à UMC, i.e., objeto mais pequeno passível de ser identificado, inviabiliza a aplicação de técnicas avançadas de classificação como é o caso da lógica difusa, ao mesmo tempo que condiciona a utilização de parâmetros relacionados com a forma dos objetos. No entanto, consubstanciou-se a ideia já demonstrada em estudos anteriores (Lang e Langanke, 2006) de que para casos específicos um nível de representação (*One Level Representation* [OLR]) pode ser suficiente e mais linear/simples.

No âmbito de todo este processo, e não obstante todas as suas valências, emergiu uma desvantagem do eCognition®, mais especificamente a sua falta de capacidade para o necessário pré-processamento dos dados de deteção remota. Estas etapas de pré-processamento são indispensáveis e implicaram o recurso a programas adicionais. Esta situação, embora à primeira vista possa parecer de somenos importância pode, num contexto mais operacional, dificultar ou mesmo inviabilizar a reprodutibilidade do processo e consequentemente a obtenção de cartografia atualizada de ocupação do solo.

Ainda assim, relevando este pequeno-grande *handicap*, entende-se que para além do objetivo principal desta dissertação ter sido cumprido, esta apresenta resultados bastante satisfatórios. De forma a enfatizar o papel do cálculo de limiares, o teste à sensibilidade do método permitiu perceber que o cálculo dos limiares de corte permite uma classificação mais aproximada à realidade. Desde que corretamente aplicado e selecionadas as melhores imagens de treino, o algoritmo possibilita a classificação dos elementos pretendidos em qualquer outro contexto temporal. Em suma, pode-se afirmar que foi criado um método (semi)automático de classificação de ocupação do solo para imagens multitemporais.

Pode-se então concluir que as evoluções tecnológicas e técnicas fornecem um contributo fundamental para o ordenamento do território. Crê-se que uma das valências desta dissertação foi provar que um conhecimento do mosaico de ocupação do solo, e sua evolução espaço-temporal, é imprescindível àqueles que têm a responsabilidade de gerir e decidir sobre o território.

Finalmente, saliente-se o papel que a abordagem baseada em objeto poderá ter no campo da Geografia, quando e se enquadrada num domínio temático, a partir do qual se procuram formas de análise e classificação de conhecimento e para o qual se constrói e caracteriza novas formas e novos significados. Os geógrafos não podem fugir à sua responsabilidade nesta matéria pela herança que a sua ciência lhes deixou e da qual são representantes.

Referências Bibliográficas

- Abreu D J B de (2006) *Análise de Dados II: Programa. Estudos para o Planeamento Regional e Urbano*, 69. Lisboa: Centro de Estudos Geográficos, Universidade de Lisboa.
- Addink E A, de Jong S M e Pebesma E J (2007) The importance of scale in object-based mapping of vegetation parameters with hyperspectral imagery. *Photogrammetric Engineering and Remote Sensing* 73 (8) 905 - 912.
- al Khudairy D H, Caravaggi I e Glada S (2005) Structural damage assessments from Ikonos data using change detection, object-oriented segmentation, and classification techniques. *Photogrammetric Engineering and Remote Sensing* 71 (7) 825 - 837.
- Albrecht F (2008) Assessing the spatial accuracy of object-based image classifications. In Car A, Griesebner G e Strobl J (Eds.), *Geospatial Crossroads @ GI - Forum '08. Proceedings of the Geoinformatics Forum Salzburg*. Wichmann Verlag, Heidelberg, 11 - 20.
- Aplin P, Atkinson P M e Curran P J (1999) Fine spatial resolution simulated satellite sensor imagery for land cover mapping in the United Kingdom. *Remote Sensing of Environment* 68 (3) 206 - 216.
- Arbiol R, Zhang Y e Palá (2006) Advanced classification techniques: a review. ISPRS Commission VII Mid-term Symposium "From Pixel to Processes", Enschede, NL, 8-11 May 2006.
- Aubrecht C, Steinnocher K, Hollaus M e Wagner W (2008) Integrating earth observation and GIScience for high resolution spatial and functional modeling of urban land use. *Computers, Environment and Urban Systems* 33 (1) 15 - 25.
- Baatz M e Schäpe A (1999) Object-oriented and multi-scale image analysis in semantic networks. *Proceedings of the 2nd International Symposium on Operationalization of Remote Sensing*, 16 - 20 August, Enschede, The Netherlands. Enschede, CD-Rom.
- Baatz M e Schäpe A (2000) Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation. In Strobl J e Blaschke T (Eds.): *Angewandte Geographische Informationsverarbeitung XII. Nova Iorque: Beiträge zum AGIT-Symposium Salzburg*. Heidelberg.

- Baatz M, Benz U, Dehghani S, Heynen M, Holtje A, Hofmann P, Lingenfelder I, Mimler M, Sohlbach M, Weber M e Willhauck G (2003) eCognition – Object Oriented Image Analysis User Guide 3. Munique: Definiens Imaging, 443.
- Baatz M, Hoffmann C e Willhauck G (2008) Progressing from object-based to object-oriented image analysis. In Blaschke T, Lang S e Hay G (Eds.). Berlim: Springer Berlin Heidelberg, 3 (27), 29 - 42.
- Baltsavias E P (2004) Object extraction and revision by image analysis using existing geodata and knowledge: Current status and steps towards operational systems. ISPRS Journal of Photogrammetry and Remote Sensing 58 (3:4) 129 - 151.
- Bardossy A e Duckstein L (1995) Fuzzy Rule-Based Modeling with Application to Geophysical, Biological and - Engineering Systems: CRC Press, New York, 232 p. Billot, A., 1992, Economic Theory of Fuzzy Equilibria -An Axiomatic System: SpringerVerlag, New York.
- Bariou R (1978) Manuel de télédétection. Paris, Sodipe.
- Benz U, Hofmann P, Willhauck G, Lingenfelder I e Heynen M (2004) Multi-resolution, object-oriented fuzzy analysis of remote sensing data for gis-ready information. ISPRS Journal of Photogrammetry e Remote Sensing 58 (2004), 239 - 258.
- Bhaskaran S, Paramananda S e Ramnarayan M (2010) Per-píxel and object-oriented classification methods for mapping urban features using Ikonos satellite data. Applied Geography, 30, Climate Change and Applied Geography - Place, Policy, and Practice, 650-665.
- Bian L (2007) Object-oriented representation of environmental phenomena: Is everything best represented as an object? Annals of the Association of American Geographers 97 (2), 267 - 281.
- Bibby P e Shepherd J (1999) Monitoring Land Cover and Land Use for Urban and Regional Planning. In Geographical Information Systems. P. A. Longley *et al.* New York: John Wiley e Sons, Inc, 2, 953-965.
- Bins L, Fonseca L e Erthal G (1996) Satellite imagery segmentation: a region growing approach. In Simpósio Brasileiro de Sensoriamento Remoto. Salvador: INPE, 8, 677 - 680.
- Blaschke T (2000) Object extraction and rule-based classification of remote sensing data: New opportunities for GIS users and planners. In M Schrenk (Ed.), CORP'2000. Technical University of Vienna.

- Blaschke T e Kux H (Eds.) (2005) Sensoriamento remoto e SIG avançados. Novos sistemas sensores - métodos inovadores. Brasil, Sao Paulo: Oficina de Textos, 242.
- Blaschke T e Strobl J (2001) What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. GIS - Zeitschrift für Geoinformationssysteme 14 (6) 12 - 17.
- Blaschke T, Burnett C e Pekkarinen A (2004) New contextual approaches using image segmentation for object-based classification. In De Meer F e de Jong S (Eds.), Remote Sensing Image Analysis: Including the spatial domain. Dordrecht: Kluwer Academic Publishers, 211 - 236.
- Blaschke T, Lang S e Hay G J (Eds.) (2008) Object Based Image Analysis. Berlim: Springer Berlin Heidelberg, 817.
- Blaschke T, Lang S, Lorup E, Strobl J e Zeil P (2000) Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. In: Cremers A, Greve K (Eds.), Environmental Information for Planning, Politics and the Public. Marburg: Metropolis Verlag, 2, 555 - 570.
- Böhner J, Selige T e Ringeler A, (2006) Image segmentation using representativeness analysis and region growing. In: Böhner J, McCloy K, Strobl, J (Eds.), SAGA - Analyses and Modelling Applications. In Göttinger Geographische Abhandlungen. Göttingen: 115, 29 - 38.
- Bontemps S, Bogaert P, Titeux N e Defourny P (2008) An object-based change detection method accounting for temporal dependences in time series with medium to coarse spatial resolution. Remote Sensing of Environment 112 (6) 3181 - 3191.
- Bossard M, Feranec J e Otahel J (2000) CORINE land cover technical guide - Addendum 2000. European Environmental Agency. Copenhaga: 105.
- Briassoulis H (2000) Analysis of Land Use Change: Theoretical and Modeling Approaches. Site disponível: The Web Book of Regional Science – Regional Research Institute, West Virginia University (última atualização: 2005), URL: <http://www.rri.wvu.edu/WebBook/Briassoulis/contents.htm>.
- Bunting P J e Lucas R M (2006) The delineation of tree crowns in Australian mixed species forests using hyperspectral Compact Airborne Spectrographic Imager (CASI) data. Remote Sensing of Environment 101, 230 - 248.
- Burnett C e Blaschke T (2002) Objects/not-objects and near-decomposability: Ecosystems and GI. In NCGIA (Ed.). Boulder: GIScience 2002, 225 - 229.

- Burnett C e Blaschke T (2002) Objects/not-objects and near-decomposability: Ecosystems and GI. In: NCGIA (Ed.), GIScience, Boulder 225-229.
- Burnett C e Blaschke T (2003) A multi-scale segmentation/object relationship modelling methodology for landscape analysis. *Ecological Modelling* 168 (3) 233 - 249.
- Caetano M, Santos T e Gonçalves L (2002) Cartografia de Ocupação do Solo com Imagens de Satélite: Estado da Arte. Atas do VII Encontro de Utilizadores de Informação Geográfica.
- Caetano, Mário; Pereira, Maria; Carrão, Hugo; Araújo, António; Nunes, António; Nunes, Vasco 2008. Cartografia Temática de Ocupação / Uso do Solo. Lisboa, Instituto Geográfico Português, 23.
- Câmara G, Souza R C M, Freitas U M e Garrido J (1996) Spring: Integrating remote sensing and GIS by object-oriented data modeling. *Computers e Graphics* 20 (3), 395 - 403.
- Campbell J B (1996) Introduction to Remote Sensing. 2ª edição. Nova Iorque: Taylor e Francis.
- Castilla G e Hay G J (2006) Uncertainties in land use data. *Hydrology and Earth System Sciences* 3 (6) 3439 - 3472.
- Castilla G, Hay G J e Ruiz J R (2008) Size-constrained region merging (SCRM): An automated delineation tool for assisted photointerpretation. *Photogrammetric Engineering e Remote Sensing* 74 (4) 409 - 419.
- Centeno J A S (2004) Sensoriamento remoto e processamento de imagens digitais. Manual técnico. Curso de Pós-Graduação em Ciências Geodésicas, Universidade Federal do Paraná.
- Chen Y, Shi P, Fung T, Wang J, Li Y (2007) Object-oriented classification for urban land cover mapping with ASTER imagery. *International Journal of Remote Sensing* 28 (29) 4645 - 4651.
- Chrisman N R (1975) Topological information systems for geographic representation. Proceedings of Second International Symposium on Computer-Assisted Cartography (Auto-Carto 2), Falls Church: ASPRS/ACSM, 346 - 351.
- Chubey M S, Franklin S E e Wulder M A (2006) Object-based analysis of IKONOS- 2 imagery for extraction of forest inventory parameters. *Photogrammetric Engineering e Remote Sensing* 72 (4) 383 - 394.
- Congalton R G (1991) A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 49 (12) 1671 - 1678.

- Congalton R G e Green K (2009) *Assessing the Accuracy of Remotely Sensed Data: principles and practices*. 2ª edição. Nova Iorque: CRC Press. Taylor e Francis Group.
- Corcoran P e Winstanley A (2008) Using texture to tackle the problem of scale in land-cover classification. In Blaschke T, Lang S e Hay G (Eds.). *Berlim: Springer Berlin Heidelberg*, 113 - 132.
- Costa H (2008) *Estratégia Multi-temporal para Produção Automática de Cartografia de Ocupação do Solo com Imagens AWiFS*. Dissertação de Mestrado em Ciência e Sistemas de Informação Geográfica. Lisboa: Instituto Superior de Estatística e Gestão de Informação, Universidade Nova de Lisboa.
- Couclelis H (1992) Location, place, region, and space. In *Geography's Inner Worlds*. Editors R F Abler, M G Marcus e J M Olson, 215-33. New Brunswick, NJ: Rutgers University Press.
- Cova T J e Goodchild M F (2002) Extending geographical representation to include fields of spatial objects. *International Journal of Geographical Information Science* 16 (6) 509 - 532.
- Cox, E (1994) *The fuzzy systems handbook: a practitioner's guide to building, using, and maintaining fuzzy systems*. New York: AP Professional.
- Cracknell A P (1998) Synergy in remote sensing - What's in a pixel? *International Journal of Remote Sensing* 19 (11) 2025 - 2047.
- Crosta A P (1993) *Processamento Digital de Imagens de Sensoriamento Remoto*. São Paulo, Campinas: IG/UNICAMP.
- Cutter S L, Golledge R e Graf W L (2002) The big questions in geography. *The Professional Geographer* 54 (3) 305 - 317.
- Di Gregorio A e Jansen L J M (2000) *Land Cover Classification System (LCCS): Classification Concepts and User Manual*. Rome: FAO.
- Díaz Varela R A, Ramil Rego P, Calvo Iglesias S e Muñoz Sobrino C (2007) Automatic habitat classification methods based on satellite images: A practical assessment in the NW Iberia coastal mountains. *Environmental Monitoring Assessment*, 144, 229 - 250.
- Dobson J E (1993) Land cover, land use differences distinct. *GIS World* 6 (2) 20-22.
- Duveiller G, Defourny P, Desclée B e Mayaux P (2008) Deforestation in Central Africa: Estimates at regional, national and landscape levels by advanced processing of

- systematically-distributed Landsat extracts. *Remote Sensing of Environment* 112 (5) 1969 - 1981.
- Eastman J R (2009) *IDRISI Taiga – Guide to GIS and Image Processing*. Clark Labs. IDRISI Production. Clark University.
- Ehlers M, Gähler M e Janowsky R (2006) Automated techniques for environmental monitoring and change analyses for ultra high-resolution remote sensing data. *Photogrammetric Engineering e Remote Sensing* 72 (7) 835 - 844.
- Encarnação S (2004) *Análise de Imagem Orientada a Objecto*. Dissertação de Mestrado em Gestão do Território. Lisboa: Faculdade de Ciências Sociais e Humanas, Universidade Nova de Lisboa.
- Encarnação S, Tenedório J A e Rocha J (2004) *Segmentação Multiresolução e Classificação Orientada a Objecto de Imagens SPOT*. CD-ROM Proceedings VIII Encontro de Utilizadores de Informação Geográfica, Oeiras, USIG.
- Espindola G M de (2007) *Ajuste de parâmetros em algoritmos de segmentação de imagens por crescimento de regiões*. Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, Ministério da Ciência e Tecnologia.
- EUROSTAT (2000) *Manual of Concepts on Land Cover and Land Use Information Systems*. Luxemburgo: Office for Official Publications of the European Communities.
- FAO/IIASA (1993) *Agro-ecological assessments for national planning: the example of Kenya*. Rome: FAO Soils Bul, 67.
- Flanders D, Hall-Beyer M e Pereverzoff J (2003) Preliminary evaluation of eCognition object-based software for cut block delineation and feature extraction. *Canadian Journal of Remote Sensing* 29 (4) 441 - 452.
- Fonseca A D e Fernandes J C (2004) *Detecção Remota: Radiação Electromagnética, Sensores Orbitais, Processamento de Imagens, Aplicações*. 1ª edição. Lisboa: Lidel – edições técnicas, Lda, 152 - 154.
- Fonseca F, Davis C e Camara G (2003) Bridging Ontologies and Conceptual Schemas in Geographic Applications Development. *Geoinformatica*, 7 (4) 355-378.
- Förstner W, Liedtke C E e Bückner J (Eds.) (1999) *SMATI 99 - Proceedings of the Semantic Modelling for the Acquisition of Topographic Information from Images and Maps*. Munich, Germany.

- França A F de, Junior J R T e Filho J C C M (2012) Índices NDVI, NDWI e NDBI como ferramentas ao mapeamento temático do entorno da lagoa olho d' água em Jaboatão dos Guararapes-PE. IV Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação, 1 - 9.
- Freire S, Santos T, Navarro A, Soares F, Silva J D, Afonso N, Fonseca A, Tenedorio J (2014) Introducing mapping standards in the quality assessment of buildings extracted from very high resolution satellite imagery. ISPRS Journal of Photogrammetry And Remote Sensing 1. Academic OneFile.
- Fritz S, Bartholome E e Belward A (2003) Harmonisation, mosaicing and production of the global land cover 2000 database. Official Publication of European Communities EUR20848, Joint Research Center. Italy: Ispra).
- Gahegan, M., 1999. Characterizing the semantic content of geographic data, models, and systems. In Goodchild M F, Egenhofer M, Fegeas R e Kottman C (Eds.), Interoperating Geographic Information Systems. Norwell: Kluwer Academic Publishers, 71 - 84.
- Gamanya R, de Maeyer P e De Dapper M (2009) Object-oriented change detection for the city of Harare, Zimbabwe. Expert Systems with Applications 36 (1) 571 - 588.
- Gao B (1996) NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. Remote Sensing of Environment, 58 (3) 257 - 266.
- Goodchild M F (1992) Geographical information science. International Journal of Geographical Information Systems 6 (1) 31 - 45.
- Goodchild M F (2004) GIScience, geography, form, and process. Annals of the Association of American Geographers 92 (4) 709 - 714.
- Goodchild M F e Longley P A (1999) The future of GIS and spatial analysis. In: Longley, P A, Goodchild M F, Maguire J, Rhind D W (Eds.), Geographical Information Systems: Principles, Techniques, Applications and Management. Wiley, Nova Iorque: 567 - 580.
- Gorte B (1998) Probabilistic Segmentation of Remotely Sensed Images. Holanda, Enschede: ITC Publication Series, 63.
- Greenhood, David (1964) Mapping. University of Chicago Press, Chicago, USA.
- Grenier M, Labrecque S, Benoit M e Allard M (2008) Accuracy assessment method for wetland object-based classification. In Proceedings GEOBIA, 2008 - Pixels, Objects, Intelligence: GEOgraphic Object Based Image Analysis for the 21st Century, 285 - 289.

- Hall O, Hay G J, Bouchard A e Marceau D J (2004) Detecting dominant landscape objects through multiple scales: An integration of object-specific methods and watershed segmentation. *Landscape Ecology* 19 (1) 59 - 76.
- Haralick R e Shapiro L (1992) *Computer and Robot Vision*. Addison-Wesley, Reading, 1.
- Haralick R M (1983) Decision making in context. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 5 (4) 417 - 428.
- Haralick R M e Shapiro L G. (1985) Survey Image segmentation techniques. *Computer Vision, Graphics, and Image Processing*, 29, 100 - 132.
- Hay G J e Castilla G (2008) Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. In Blaschke, T., Lang, S. e Hay G. (Eds.). Berlin: Springer Berlin Heidelberg, 93 - 112.
- Hay G J, Blaschke T, Marceau D J e Bouchard A (2003) A comparison of three image-object methods for the multiscale analysis of landscape structure. *ISPRS Journal of Photogrammetry and Remote Sensing* 57 (5 - 6) 327 - 345.
- Hay G J, Castilla G, Wulder M A e Ruiz J R (2005) An automated object-based approach for the multiscale image segmentation of forest scenes. *International Journal of Applied Earth Observation and Geoinformation* 7 (4) 339 - 359.
- Hay G J, Marceau D J, Dube P, Bouchard A (2001) A multiscale framework for landscape analysis: Object-specific analysis and upscaling. *Landscape Ecology* 16 (6) 471 - 490.
- Herold M, Gardner M E e Roberts D A (2003) Spectral resolution requirements for mapping urban areas. *IEEE Trans. Geosci. Remote Sens*, 41, 1907–1919.
- Herold M, Roberts D A, Gardner M E e Dennison P E (2004) Spectrometry for urban area remote sensing - Development and analysis of a spectral library from 350 to 2400 nm. *Remote Sensing of Environment*, 91 (3-4) 304 - 319.
- Hese S e Schmillius C (2008) Object-oriented oil spill contamination mapping in West Siberia with Quickbird data. In Blaschke T, Lang S e Hay G (Eds.). Berlin: Springer Berlin Heidelberg, 367 - 382.
- Hester D B, Cakir H I, Nelson S A C, e Khorram S (2008) Per-pixel classification of high spatial resolution satellite imagery for urban land-cover mapping. *Photogrammetric Engineering and Remote Sensing*, 74 (4) 463 - 471.
- Hölbling D e Neubert M (2008) ENVI Feature Extraction 4.5. Snapshot. In *GIS Business*, 7, 48 - 51.

- Hoover E M e Giarratani F (1984) An introduction to regional economics. Nova Iorque: Alfred K.
- Ivits E e Koch B (2002) Object-oriented remote sensing tools for biodiversity assessment: A European approach. In Proceedings 22^o EARSeL Symposium. Praga: Millpress Science Publishers.
- Ivits E, Koch B, Blaschke T, Jochum M e Adler P (2005) Landscape structure assessment with image grey-values and object-based classification at three spatial resolutions. *International Journal of Remote Sensing* 26 (4) 2975 - 2993.
- Jacquin A, Misakova L e Gay M (2008) A hybrid object-based classification approach for mapping urban sprawl in periurban environment. *Landscape and Urban Planning* 84 (2) 152 - 165.
- Jensen J R (2000) *Remote Sensing of the Environment: an earth resources perspective*. USA, New Jersey: Prentice Hall, Upper Saddle River.
- Jensen J R (2004) *Introductory Digital Image Processing – A Remote Sensing Perspective*. 3^a edição. USA: Prentice Hall, Upper Saddle River.
- Jobin B, Labrecque S, Grenier M e Falardeau G (2008) Object-based classification as an alternative approach to the traditional pixel-based classification to identify potential habitat of the grasshopper sparrow. *Environmental Management* 41 (1) 20 - 31.
- Johansen K, Coops N C, Gergel S E e Stange J (2007) Application of high spatial resolution satellite imagery for riparian and forest ecosystem classification. *Remote Sensing of Environment* 110 (1), 29 - 44.
- Jones A e Clark J (1997) Driving forces behind European land use change: an overview. In *The user needs for more harmonized land use information at the national and EU level. Report on the CLAUDE (Coordinating Land Use and Cover Data Analyses in Europe) Workshop*. Wageningen: CLAUDE, Concerted Action, EC. v. DGXII, 24-31.
- Kampouraki M, Wood G A e Brewer T R (2008) Opportunities and limitations of object-based image analysis for detecting urban impervious and vegetated surfaces using true-colour aerial photography. In Blaschke, T., Lang, S. e Hay G. (Eds.). *Berlim: Springer Berlin Heidelberg*, 555 - 569.

- Kettig R e Landgrebe D (1976) Classification of multispectral image data by extraction and classification of homogeneous objects. *IEEE Transactions on Geoscience Electronics* GE-14 (1), 19 - 26.
- Koestler A (1967) *The Ghost in the Machine*. Nova Iorque: Random House.
- Koestler A (1967) *The Ghost in the Machine*. Random House, New York.
- Kosko B (1992) *Neural networks and fuzzy systems: a dynamical systems approach to machine intelligence*. Englewood Cliffs: Prentice Hall.
- Krause G, Bock M, Weiers S e Braun G (2004) Mapping land-cover and mangrove structures with remote sensing techniques: A contribution to a synoptic GIS in support of coastal management in North Brazil. *Environmental Management* 34 (3), 429 - 440.
- Kuechler A W e Zonneveld I S (Eds) (1988) *Vegetation mapping*. Dr W Junk. Dordrecht. ISBN 90-6193-191-6.
- Kunz D, Vögtle T e Schilling K J (1998) Integrated processing of satellite images and vectorial map information. In HP Bähr e T Vogtle (Ed.). *Digital Image Processing: Application in photogrammetry, cartography and remote sensing*. Heidelberg, New York.
- Lackner M e Conway T M (2008) Determining land-use information from land cover through an object-oriented classification of IKONOS imagery. *Canadian Journal of Remote Sensing* 34 (2) 77 - 92.
- Lang S (2005) *Image objects vs. landscape objects. Interpretation, hierarchical representation and significance*. Salzburg.
- Lang S (2005) *Image objects vs. landscape objects. Interpretation, hierarchical representation and significance*, Salzburg (unpublished Ph.D. thesis).
- Lang S (2008) Object-based image analysis for remote sensing applications: Modeling reality - Dealing with complexity. In Blaschke T, Lang S e Ha, G J (Eds.), *Object Based Image Analysis*. Berlin: Springer Berlin Heidelberg, 3 - 27.
- Lang S (2008) Object-based image analysis for remote sensing applications: Modeling reality _ Dealing with complexity. In Blaschke, T., Lang, S. e Hay G. (Eds.). Berlin: Springer Berlin Heidelberg 1-25.
- Lang S e Langanke T (2006) Object-based mapping and object-relationship modeling for land use classes and habitats. *Photogrammetrie, Fernerkundung, Geoinformation* 10 (1) 5 - 18.
- Lang S e Tiede D (2007) Definiens Developer. *GIS Business*, 9, 34 - 37.

- Lillesand T M, Kiefer R W e Chipman J W (2003) *Remote Sensing and Image Interpretation*. Hoboken: John Wiley e Sons.
- Liu Y, Li M, Mao L e Xu F (2006) Review of remotely sensed imagery classification patterns based on object oriented image analysis. *Chinese Geographical Science* 16 (3), 282 - 288.
- Lobo A, Chick O e Casterad A (1996) Classification of Mediterranean crops with multisensor data: Per-pixel versus per-object statistics and image segmentation. *International Journal of Remote Sensing* 17 (12), 2385 - 2400.
- Lu D e Weng Q (2006) Use of impervious surface in urban land-use classification. *Remote Sens. Environ*, 102, 146–160.
- Lu D e Weng Q (2007) A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28 (5), 823 - 870.
- Lucieer V L (2008) Object-oriented classification of sidescan sonar data for mapping benthic marine habitats. *International Journal of Remote Sensing* 29 (3), 905 - 921.
- Magarotto M, Tenedório J, Silva C e da Costa, M (2015) Vertical growth in a coastal city: an analysis of Boa Viagem. Recife, Brazil: *Journal of Coastal Conservation*, 1-12.
- Maier B, Tiede D e Dorren I (2008) Characterising mountain forest structure using landscape metrics on LiDAR-based canopy surface models In Blaschke, T., Lang, S. e Hay G. (Eds.). Berlin: Springer Berlin Heidelberg 625 - 644.
- Malczewski J (2003) GIS-based land-use suitability analysis: a critical overview. *Progress in Planning*, 62, 3 - 65.
- Mallinis G, Koutsias N, Tsakiri-Strati M e Karteris M (2008) Object-based classification using Quickbird imagery for delineating forest vegetation polygons in a Mediterranean test site. *ISPRS Journal of Photogrammetry and Remote Sensing* 63 (2) 237 - 250.
- Marceau D (1999) The scale issue in the social and natural sciences. *Canadian Journal of Remote Sensing* 25 (4) 347 - 356.
- Marpu P R, Niemeyer I, Nussbaum S e Gloaguen R (2008) A procedure for automatic object-based classification. In Blaschke T, Lang S e Hay G (Eds.). Berlin: Springer Berlin Heidelberg, 169 - 184.
- Martins F D (2012) Utilização de técnicas de Detecção Remota na identificação de *Acacia* sp. na região Centro Sul de Portugal Continental. Dissertação de Mestrado em Sistemas

de Informação Geográfica em Recursos Agro-Florestais e Ambientais. Castelo Branco: Escola Superior Agrária, Instituto Politécnico de Castelo Branco.

Mather A S (1986) *Land Use*, Longman. Reino Unido, Essex: 286.

Mather P M (2004) *Computer Processing of Remotely Sensed Images. An Introduction*. Chichester: John Wiley e Sons.

McFeeters S K (2013) Using the normalized difference water index (NDWI) within a geographic information system to detect swimming pools for mosquito abatement: A practical approach. *Remote Sensing*, 5 (7) 3544 - 3561.

McKeown D M, Harvey W A e Wixson L E (1989) Automating knowledge acquisition for aerial image interpretation. *Computer Vision, Graphics, and Image Processing* 46 (1) 37 - 81.

Messina J P e Crews-Meyer K A (2005) The Integration of Remote Sensing and Medical Geography: Process and Application. *Spatial Analysis, GIS, and Remote Sensing Applications in the Health Sciences*, 147 - 176.

Myint S W, Yuan M, Cervený R S e Giri C P (2008) Comparison of remote sensing image processing techniques to identify tornado damage areas from landsat TM data. *Sensors* 8 (2) 1128 - 1156.

Navulur K (2007) *Multispectral image analysis using the object-oriented paradigm*. Boca Raton, FL: CRC Press.

Neubert M e Meinel G (2003) Comparison of segmentation programs for remote sensing data. *Applied Geographical Information Processing XV, Symposium Salzbur*, 323-329.

Neubert M, Herold H e Meinel G (2008) Assessing image segmentation quality - Concepts, methods and application. In Blaschke T, Lang S e Hay G J (Eds.), *Object Based Image Analysis*. Berlin: Springer Berlin Heidelberg, 760 - 784.

Niemeyer I (2001) *Satellites and nuclear control. Change detection and object-oriented classification based on knowledge to support for nuclear verification*. Forschungszentrum Jülich, Number Environment.

Niemeyer I, Marpu P R e Nussbaum S (2008) Change detection using object features. In Blaschke T, Lang S e Hay G (Eds.). Berlin: Springer Berlin Heidelberg, 185 - 201.

Nussbaum S e Menz G (2008) Object-based image analysis and treaty verification. In *New Approaches in Remote Sensing - Applied to Nuclear Facilities in Iran*. Berlin: Springer Berlin Heidelberg, 218.

- Ojala T e Pietikainen M (1999) Unsupervised texture segmentation using feature distributions. *Pattern Recognition*, 32 (3) 477 - 486.
- Oliveira F (2011) Análise Comparativa de Classificadores para Cartografia de Ocupação do Solo no Alentejo, com Imagens Intra-Anuais AWiFS. Dissertação de Mestrado em Gestão do Território, área de Especialização em Detecção Remota e Sistemas de Informação Geográfica. Lisboa: Faculdade d Ciências Sociais e Humanas, Universidade Nova de Lisboa.
- Opitz D e Blundell S (2008) Object recognition and image segmentation: The Feature Analyst[®] approach. In Blaschke T, Lang S e Hay G (Eds.). Berlim: Springer Berlin Heidelberg, 153 - 167.
- Pal R e Pal K (1993) A review on image segmentation techniques. *Pattern Recognition*, 26 (9) 1277 - 1294.
- Pardal S C (1988) Planeamento do Território. Instrumentos para a Análise Física.
- Pascual C, García-Abril A, García-Montero L G, Martín-Fernández S, Cohen W B (2008) Object-based semi-automatic approach for forest structure characterization using lidar data in heterogeneous *Pinus sylvestris* stands. *Forest Ecology and Management*, 255 (11) 3677 - 3685.
- Peuquet D J (1984) It's about time: a conceptual framework for the representation of temporal dynamics in geographic information systems. *Annals of the Association of American Geographers*, 3, 441 - 61.
- Pinho C M D, Fonseca L M G, Korting T S, Almeida C M e Kux J H (2012) Land Cover Classification of an intra-urban environment using high-resolution images and object-based image analysis. *International Journal of Remote Sensing* 33 (19), 5973 - 5995.
- Platt R V e Rapoza L (2008) An evaluation of an object-oriented paradigm for land use/land cover classification. *The Professional Geographer*, 60 (1) 87 - 100.
- Radoux J e Defourny P (2008) Quality assessment of segmentation results devoted to object-based classification. In Blaschke T, Lang S e Hay G (Eds.). Berlim: Springer Berlin Heidelberg, 257 - 271.
- Richards J A e Jia X (1999) *Remote Sensing Digital Image Analysis. An Introduction*. Berlim: Springer Berlin Verlag.
- Richards J A e Jia X (2006) *Remote Sensing Digital Image Analysis: An Introduction*. 4ª edição. Berlim: Springer-Verlag Berlin Heidelberg.

- Rocha J (2012) *Sistemas Complexos, Modelação e Geosimulação da Evolução de Padrões de Uso de Ocupação do Solo*. Dissertação de Doutoramento em Geografia e Ciências da Informação. Lisboa: Instituto de Geografia e Ordenamento do Território, Universidade de Lisboa.
- Rocha J, Queluz M P e Tenedório J A (2001) IDECIS: Integração de Dados Censitários na Classificação de Imagens de Satélite, ESIG2001 – VI Encontro de Utilizadores de Informação Geográfica. USIG, novembro, Lisboa.
- Roque D, Afonso N, Fonseca A e Heleno S (2014) OBIA Flood Delimitation Assisted by Threshold Determination with Principal Component Analysis. *Photogrammetric Engineering and Remote Sensing*, 80 (59) 551 - 557.
- Sagerer G e Niemann H (1997) *Semantic Networks for Understanding Scenes*. Advances in Computer Vision and Machine Intelligence. Nova Iorque: Plenum Press.
- Schiewe J (2002) *Segmentation of High-Resolution remotely sensed Data – Concepts, Applications and Problems*. Symposium on Geospatial Theory, Processing Applications. Ottawa.
- Schiewe J e Tufte L (2001) Potential region- based methods for the evaluation of integrative GIS and remote sensing data. In Blascke T (Ed.) Wichmann: Verlag, Heidelberg, 42 - 52.
- Schöpfer E e Möller M S (2006) Comparing metropolitan areas - Transferable object-based image analysis approach. *Photogrammetrie, Fernerkundung, Geoinformation* 10 (4) 277 - 286.
- Schott J R (1997) *Remote Sensing. The Image Chain Approach*. Nova Iorque: Oxford University Press.
- Schowengerdt R A (1997) *Remote Sensing – Models and Methods for Image Processing*. 2ª edição. San Diego: Academic Press.
- Shackelford A K e Davis C H (2003) A hierarchical fuzzy classification approach for high-resolution multispectral data over urban areas. *IEEE Transactions on Geoscience and Remote Sensing* 41 (9) 1920 - 1932.
- Shiba M e Itaya A (2006) Using eCognition for improved forest management and monitoring systems in precision forestry. In Ackerman P A, Längin D W e Antonides M C (Eds.), *Precision Forestry in plantations, semi-natural and natural forests*. Proceedings International Precision Forestry Symposium, Stellenbosch University, South Africa, Stellenbosch.

- Simon H A (1973) The organization of complex systems. In: Pattee, H.H. (Ed.), *Hierarchy Theory: The Challenge of Complex Systems*. George Braziller, Cambridge, 1 - 27.
- Simon H A (1973) The organization of complex systems. In: Pattee, H.H. (Ed.), *Hierarchy Theory: The Challenge of Complex Systems*. George Braziller, New York, Cambridge, 1 - 27.
- Skole D L (1994) Data on global land-cover change: Acquisition, assessment, and analysis. In Meyer W B e Turner B L II. *Changes in land use and land cover: a global perspective*. Cambridge, UK: Cambridge University Press, 437-471.
- Smith B (2001) Fiat Objects. *Topoi*, 20 (2) 131-148.
- Smith B e Mark D (1998) Ontology and Geographic Kinds. In: *International Symposium on Spatial Data Handling*. Vancouver, Canada: 308- 320.
- Smith M (1998) Painting by numbers—mathematical models of urban systems. *Environment and Planning B*, 25: 483 - 493.
- Sokal R (1974) Classification: purposes, principles, progress, prospects. *Science*, 185(4157) 111-123.
- Sonka M, Hlavac V e Boyle R (1998) *Image processing, Analyses and Machine Vision*, 2. Auflage. PWS Publishing, Pacific Grove.
- Stehman S (2001) Statistical rigour and practical utility in thematic map accuracy. *Photogrammetric Engineering & Remote Sensing*, 67, 727-734.
- Stehman S, Czaplewski R, Nusser S, Yang L e Zhu Z (2000) Combining accuracy assessment of land-cover maps with environmental monitoring programs. *Environmental monitoring and assessment*, 64, 115 -126.
- Stewart G A (1968) *Land Evaluation*. In Stewart G A (ed) *Land Evaluation*. Macmillan, Melbourne.
- Stow D, Hamada Y, Coulter L e Anguelova Z (2008) Monitoring shrubland habitat changes through object-based change identification with airborne multispectral imagery. *Remote Sensing of Environment* 112 (3) 1051 - 1061.
- Strahler A, Woodcock C e Smith J (1986) On the nature of models in remote sensing. *Remote Sensing of Environment*, 20, 121 - 139.
- Tenedório J A, Ferreira, J C, Rocha J, Sousa P, Mota G e Pontes S (1999) Carta de Uso do Solo da Área Metropolitana de Lisboa (CARTUS-AML), *Actas do VIII Colóquio Ibérico de Geografia*, Volume II, DGPR-UNL, Lisboa, 711-716.

- Tenedório J A, Rocha J, Encarnação S e Estanqueiro R (2006) Cartografia de Uso e Ocupação do Solo: Classificação vectorial com redes neuronais orientadas para objecto, CD-ROM Proceedings, IX Encontro de Utilizadores de Informação Geográfica, Oeiras, USIG.
- Tiede D, Lang S e Hoffmann C (2008) Domain-specific class modelling for one-level representation of single trees. In Blaschke T, Lang S e Hay G (Eds.). Berlim: Springer Berlin Heidelberg, 133 - 151.
- Tilton J C (1998) Image segmentation by region growing and spectral clustering with a natural convergence criterion. In Geoscience and Remote Sensing Symposium Proceedings, 1998 IEEE International 4, 1766 - 1768.
- Tönjes R (1999) Knowledge-based interpretation and 3D reconstruction of landscape scenes from aerial photographs. Progress Reports VDI 10 (575).
- Tönjes R, Growe S, Bückner J e Liedtke C E (1999) Knowledge-based interpretation of remote sensing images using semantic nets. Photogrammetric Engineering e Remote Sensing, 65 (7), 811–821.
- Trias-Sanz R, Stamon G e Louchet J (2008) Using colour, texture, and hierarchical segmentation for high-resolution remote sensing. ISPRS Journal of Photogrammetry and Remote Sensing 63 (2) 156 - 168.
- Trimble (2012) eCognition Developer 8.8 Reference Book. Munique: Trimble Documentation.
- Turner II B L, e Meyer W B (1994) Changes in land use and land cover: a global perspective. Cambridge, Reino Unido: Cambridge University Press.
- Turner II B L, Skole D L, Sanderson S, Fischer G, Fresco L O, Leemans R (1995) Land-Use and Land-Cover Change Science – Research Plan. Site disponível: International Human Dimensions Programme On Global Environmental Change, URL: <http://www.ihdp.uni-bonn.de/html/publications/reports/report07/luccsp.htm#toc>.
- USGS (2015) Landsat 8 (L8) Data Users Handbook. 1ª edição. Department of the Interior, U.S. Geological Survey. Sioux Falls, South Dakota
- van der Werff H M A, van der Meer F D (2008) Shape-based classification of spectrally identical objects. ISPRS Journal of Photogrammetry and Remote Sensing 63 (2) 251 - 258.
- Vicini L (2005) Análise multivariada da teoria à prática.
- Walker J S e Briggs J M (2007) An object-oriented approach to urban forest mapping in phoenix. Photogrammetric Engineering e Remote Sensing 73 (5) 577 - 583.

- Walker J S, Blaschke T (2008) Object-based land cover classification for the Phoenix metropolitan area: Optimization vs. transportability. *International Journal of Remote Sensing* 29 (7), 2021 - 2040.
- Webster C J (1996) Urban morphology fingerprints. *Environment and Planning B*, 23, 279 - 297.
- Weidner U (2008) Contribution to the assessment of segmentation quality for remote sensing applications. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37 (Part B7).
- Weinke E, Lang S e Preiner M (2008) Strategies for semi-automated habitat delineation and spatial change assessment in an Alpine environment. In Blaschke T, Lang S e Hay G (Eds.). *Berlin: Springer Berlin Heidelberg*, 711 - 732.
- Weng Q (2008) Remote Sensing of Impervious Surfaces: An Overview. In *Remote Sensing of Impervious Surfaces*; Weng, Q., Ed.; CRC Press, Taylor & Francis Group: Boca Raton, FL, USA.
- Wilkinson G G (1999) Recent developments in remote sensing technology and the importance of computer vision analysis techniques. In I Kanellopoulos, G Wilkinson e Moons T (Eds.): *Machine Vision and Advanced Image Processing in Remote Sensing*. Berlin: Springer, 5 - 11.
- Wiseman G, Kort J e Walker D (2009) Quantification of shelterbelt characteristics using high-resolution imagery. *Agriculture, Ecosystems and Environment*, 131 (1 - 2) 111 - 117.
- Woodcock C e Harward V J (1992) Nested-hierarchical scene models and image segmentation. *International Journal of Remote Sensing*, 13 (16) 3167 - 3187.
- Wu J (1999) Hierarchy and scaling: Extrapolating information along a scaling ladder. *Canadian Journal of Remote Sensing*, 25 (4) 367 - 380.
- Wu J e David J L (2002) A spatially explicit hierarchical approach to modeling complex ecological systems: Theory and applications. *Ecological Modelling*, 153 (1 - 2) 7 - 26.
- Wu J e Loucks O L (1995) From balance-of-nature to hierarchical patch dynamics: A paradigm shift in ecology. *Quarterly Review of Biology*, 70 (4) 439 - 466.
- Wuest B e Zhang Y (2009) Region based segmentation of QuickBird multispectral imagery through band ratios and fuzzy comparison. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64 (1) 55 - 64.

- Wulder M (1998) Optical remote-sensing techniques for the assessment of forest inventory and biophysical parameters. *Progress in Physical Geography*, 22 (4) 449 - 476.
- Yi W e Marshall S (2000) Principal component analysis in application to object orientation. *Geo-spatial Information Science*, 3 (3) 76 - 78.
- Yu Q, Gong P, Chinton N, Biging G, Kelly M e Schirokauer D (2006) Objectbased detailed vegetation classification with airborne high spatial resolution remote sensing imagery. *Photogrammetric Engineering e Remote Sensing*, 72 (7) 799 - 811.
- Zhou W e Troy A (2008) An object-oriented approach for analysing and characterizing urban landscape at the parcel level. *International Journal of Remote Sensing* 29 (11) 3119 - 3135.
- Zucker S W (1976) Region growing: childhood and adolescence. *Computer Graphics and Image Processing*, 15, 382 - 399.

Anexo

Nomenclatura CORINE Land Cover

Nível 1	Nível 2	Nível 3
1 Territórios artificializados	1.1 Tecido urbano	1.1.1 Tecido urbano contínuo 1.1.2 Tecido urbano descontínuo
	1.2 Indústria, comércio e transportes	1.2.1 Indústria, comércio e equipamentos gerais 1.2.2 Redes viárias e ferroviárias e espaços associados 1.2.3 Áreas portuárias 1.2.4 Aeroportos e aeródromos
	1.3 Áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção	1.3.1 Áreas de extração de inertes 1.3.2 Áreas de deposição de resíduos 1.3.3 Áreas em construção
	1.4 Espaços verdes urbanos, equipamentos desportivos, culturais e de lazer, e zonas históricas	1.4.1 Espaços verdes urbanos 1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas
2 Áreas agrícolas e agroflorestais	2.1 Culturas temporárias	2.1.1 Culturas temporárias de sequeiro 2.1.2 Culturas temporárias de regadio 2.1.3 Arrozais
	2.2 Culturas permanentes	2.2.1 Vinhas 2.2.2 Pomares 2.2.3 Olivais
	2.3 Pastagens permanentes	2.3.1 Pastagens permanentes
	2.4 Áreas agrícolas heterogéneas	2.4.1 Culturas temporárias e/ou pastagens associadas a culturas permanentes 2.4.2 Sistemas culturais e parcelares complexos 2.4.3 Agricultura com espaços naturais e seminaturais 2.4.4 Sistemas agroflorestais
3 Florestas e meios naturais e seminaturais	3.1 Florestas	3.1.1 Florestas de folhosas 3.1.2 Florestas de resinosas 3.1.3 Florestas mistas
	3.2 Florestas abertas, vegetação arbustiva e herbácea	3.2.1 Vegetação herbácea natural 3.2.2 Matos 3.2.3 Vegetação esclerofila 3.2.4 Florestas abertas, cortes e novas plantações
	3.3 Zonas descobertas e com pouca vegetação	3.3.1 Praias, dunas e areais 3.3.2 Rocha nua 3.3.3 Vegetação esparsa 3.3.4 Áreas ardidas
4 Zonas húmidas	4.1 Zonas húmidas interiores	4.1.1 Paus 4.1.2 Turfeiras
	4.2 Zonas húmidas litorais	4.2.1 Sapais 4.2.2 Salinas e aquicultura litoral 4.2.3 Zonas entre marés
5 Corpos de água	5.1 Águas interiores	5.1.1 Cursos de água 5.1.2 Planos de água
	5.2 Águas marinhas e costeiras	5.2.1 Lagoas costeiras 5.2.2 Desembocaduras fluviais 5.2.3 Oceano

