

**ANÁLISE COMPARADA DE SEGMENTAÇÃO E CLASSIFICAÇÃO
ORIENTADA POR OBJECTOS DE UMA IMAGEM *WORLDVIEW-2***

Cristina Garcia Franco Gabriel

**Dissertação
de Mestrado em Gestão do Território, Especialização em Detecção
Remota e Sistemas de Informação Geográfica**

Agosto, 2013

*Supposing is good, but finding
out is better.*

Mark Twain

AGRADECIMENTOS

Um especial obrigado ao meu orientador Professor José António Tenedório, pela disponibilidade e atenção dispensada, sempre receptivo à resolução das questões que foram surgindo no decorrer deste período.

Aos meus pais por me terem dado acesso a uma educação de excelência e por todo o apoio que me deram.

Aos amigos e colegas, pelo incentivo, compreensão e encorajamento, durante todo este período.

E aos demais, que me ajudaram nesta etapa...

RESUMO

ANÁLISE COMPARADA DA SEGMENTAÇÃO E CLASSIFICAÇÃO ORIENTADA POR OBJECTOS DE UMA IMAGEM DE MUITO ALTA RESOLUÇÃO *WORLDVIEW-2*

Cristina Garcia Franco Gabriel

PALAVRAS-CHAVE: Detecção Remota, Alta Resolução, Classificação, Segmentação, Pixel, Orientada por objectos.

A Detecção Remota é uma ciência e uma técnica com grande valor na área da gestão do território, em particular das cidades, auxiliando os decisores, nomeadamente na alimentação de dados para sistemas de apoio à decisão, na observação e na monitorização da superfície terrestre.

A presente dissertação de mestrado teve por objectivo geral o processamento de imagens de alta resolução espacial e espectral, usando para tal uma imagem de satélite *WorldView-2*.

Os objectivos específicos compreendem o ensaio de diferentes abordagens de classificação. Numa primeira fase, procedeu-se à classificação da imagem com aproximação ao *pixel*, de forma supervisionada, pelo algoritmo *random forests*. Numa segunda fase, executou-se a segmentação da imagem, pelo *software IDRISI Taiga*, seguida da classificação de segmentos utilizando o algoritmo *nearest neighbor* e depois o algoritmo *random forests*. Numa terceira fase procedeu-se à segmentação da imagem por objectos, com o *eCognition 8.0*, pelo algoritmo *multiresolution*, classificando-os posteriormente também pelo algoritmo *nearest neighbor*. Por fim, foi realizada uma avaliação de exactidão dos resultados das diferentes abordagens, discutindo a sua aplicabilidade na classificação de imagens de áreas urbanas densas, efectuando-se uma análise comparada das mesmas.

A área de estudo seleccionada foi uma área da cidade de Lisboa compreendendo, sobretudo, as designadas “Avenidas Novas”. Tal como a grande maioria das áreas urbanas, esta área apresenta também uma grande heterogeneidade espectral facto que permitiu avaliar a influência dessa característica na aplicação de diferentes métodos de classificação.

A classificação com maior valor para a exactidão global (EG) e índice de concordância Kappa é a *orientada por objectos*, com valores entre os 63.6 e 90.7% e os 0.60 e 0.81, respectivamente para os diferentes níveis da nomenclatura hierarquizada. As outras classificações obtiveram valores similares entre si que variam entre os 56.9% e 87.5% para EG e 0.53 e 0.72 para Kappa.

A dissertação insere-se num contexto de continuidade de uma série de trabalhos de detecção remota urbana liderados pelo Professor José António Tenedório, realizados no âmbito do Grupo de Modelação Geográfica, Cidades e Ordenamento do Território do e-GEO, Centro de Estudos de Geografia e Planeamento Regional, da Faculdade de Ciências Sociais e Humanas da Universidade Nova de Lisboa; assim como de outras equipas internacionais em matéria de processamento digital de imagens de satélite aplicado à cidade.

ABSTRACT

COMPARATIVE ANALYSIS OF SEGMENTATION AND CLASSIFICATION ORIENTED BY OBJECTS OF AN IMAGE *WorldView-2*

Cristina Garcia Franco Gabriel

KEYWORDS: Remote Sensing, Very High Resolution, Classification, Segmentation, Pixel, Object-Oriented.

Remote Sensing is a powerful and very useful tool in the field of Land Management. It assists in decision support systems since it allows observing, characterizing and monitoring land surface.

The main aim of this Master thesis was to process a high spatial and spectral resolution image from *WorldView-2* satellite.

The specific objectives of this thesis comprise the evaluation of different image classification approaches. Firstly, the image was classified using *random forests*, an algorithm based on a pixel approximation. Second, the image segmentation was performed using *IDRISI Taiga* software, and the resulting segments were classified first with the *nearest neighbor* algorithm and then with the *random forests*. Third, the segmentation by objects was executed using *eCognition 8.0*, with the algorithm *multiresolution*, and these were then classified also with the *nearest neighbor* algorithm. Finally, the accuracy of the results for each approach was determined in order to assess its applicability in image classification of an urban grid.

The scene chosen for case study lies on an area of Lisbon, which due to its spectral heterogeneity provided excellent conditions for studying the performance of these different classification methods on an urban environment.

The classification with the highest value for the overall accuracy and Kappa index is object-oriented, with values between 63.6 and 90.7% and 0.60 and 0.81, respectively, for different levels of grouping. The other classifications obtained values similar to each other ranging between 56.9% and 87.5% for EG and Kappa and 0.53 and 0.72.

This dissertation follows on a series of work done in the remote sensing field by Professor José António Tenedório, in the group of Geographic Modeling, City and Spatial Planning of the e-GEO, Research Centre for Geography and Regional Planning, Faculty of Social Sciences and Humanities, New University of Lisbon; as well as other international teams on digital image processing of satellite data applied to urban environments.

ÍNDICE

CAPÍTULO I. Introdução e contextualização.....	1
I.1. Introdução.....	1
I.2. Problema, Objecto e Metodologia.....	5
I.3. Área de Estudo.....	7
I.4. Síntese do Estado da Arte	8
CAPÍTULO II. Conhecimento de Base Teórica.....	13
II.1. A Nomenclatura	13
II. 2. Classificação <i>Pixel a Pixel</i>.....	14
II. 2.1. Classificação Não Supervisionada.....	14
II. 2.2. Classificação Supervisionada.....	16
II.3. Classificação <i>Orientada por Segmentos e por Objectos</i>.....	17
II. 3.1. Classificação <i>Orientada por Segmentos</i>.....	19
II. 3.2. Classificação <i>Orientada por objectos</i>.....	21
II. 4. Algoritmos de Classificação.....	23
II.4.1. Algoritmo <i>Random Forests</i>.....	23
II. 4.2. Algoritmo <i>Nearest Neighbor</i>.....	24
II. 5. Análise de Exactidão.....	25
II.5.1. Matriz de Confusão.....	26
II. 5.2. Índice de Concordância Kappa.....	28
CAPÍTULO III. Ensaio de Classificação de Dados <i>WORLDVIEW-2</i>.....	30
III. 1. Dados e Caso de Estudo.....	31

III. 2. Metodologia.....	33
III.2.1. Nomenclatura proposta de Classificação.....	36
III. 2.2. Ensaio de Classificação <i>WorldView-2</i>	42
III. 2.2.1. Classificação <i>Pixel a Pixel</i>	42
III. 2.2.2. Classificação <i>Orientada por Segmentos</i>	50
III. 2.2.3. Classificação Combinada, <i>Pixel a Pixel</i> agrupada por Segmentos.....	54
III. 2.2.4. Classificação <i>Orientada por Objectos</i>	54
III. 2.3. Análise de Exactidão	58
CAPÍTULO IV. Análise dos Resultados.....	60
IV. 1. Classificação <i>Pixel a Pixel</i>	61
IV. 2. Classificação <i>Orientada por Segmentos</i>	62
IV. 3. Classificação Combinada, <i>Pixel a Pixel</i> agrupada por Segmentos.....	65
IV. 4. Classificação <i>Orientada por Objectos</i>	66
CAPÍTULO V. Discussão dos Resultados.....	70
V. 1. Análise Comparada dos Processos de Segmentação.....	70
V.2. Análise de Exactidão.....	79
V.3. Reflexão Geral a partir dos Resultados.....	118
CONCLUSÃO.....	125
BIBLIOGRAFIA.....	128
LISTA DE FIGURAS.....	131
LISTA DE TABELAS.....	135
GLOSSÁRIO	137

ANEXO A: Matrizes de confusão para a Classificação <i>Pixel a Pixel</i> , para os diferentes níveis da nomenclatura.....	138
ANEXO B: Matrizes de confusão para a Classificação <i>orientada por segmentos</i> , pelo <i>IDRISI Taiga</i> , para os diferentes níveis da nomenclatura.....	142
ANEXO C: Matrizes de confusão para a Classificação Combinada, <i>Pixel a Pixel</i> , agrupada por Segmentos, para os diferentes níveis da nomenclatura.....	146
Anexo D: Matrizes de confusão para a Classificação orientada por objectos, pelo <i>eCognition 8.0</i> , para os diferentes níveis da nomenclatura.....	150

LISTA DE ABREVIATURAS E ACRÓNIMOS

C	Cor
CC	Cor e Contexto
CT	Cor e Textura
DR	Detecção Remota
EG	Exactidão global
EP	Exactidão do Produtor
EU	Exactidão do utilizador
KAPPA	Índice de Concordância Kappa
LiDAR	Light Detection and Ranging
PIXEL	Picture Element
RF	<i>Random Forests</i>
WMF	Valores de média (Weight Mean Factor)
WVF	Valores de varância (Weight Variance Factor)

CAPÍTULO I. Introdução e contextualização

I.1. Introdução

A Detecção Remota é uma ciência e uma técnica fundamental e com grande utilidade na área de Gestão do Território, auxiliando o Homem em sistemas de apoio à decisão, pois permite observar, caracterizar e supervisionar a superfície terrestre, em tempo real. Lillesand e Kiefer (2000) definem a Detecção Remota (DR) como “ (...) a ciência e a arte de obter informação de um objecto, área ou fenómeno através da análise de dados adquiridos através de um dispositivo que não está em contacto com o objecto, área ou fenómeno”. A DR visa espelhar, explicar, quantificar e descrever os padrões da superfície terrestre, contribuindo para a compreensão dos processos que lhe deram origem (Blaschke e Strobl, 2001).

O rápido crescimento dos espaços urbanos e a pressão demográfica que estes observam, traduzido na criação de zonas residenciais e infra-estruturas, tem um impacto assinalável no uso do solo. O conhecimento sobre a cobertura terrestre e o uso do solo, e como estes se alteram, é crucial para um sistema global de informação (Kai, *et al.*, 2007). A aquisição de informação de qualidade sobre a superfície terrestre, passível de se obter com a DR, é fundamental para o desenvolvimento de estratégias na gestão e ordenamento do território.

O tecido urbano é muito dinâmico, muda a cada instante, sendo difícil registar todas estas mutações na paisagem, tornando essencial um bom sistema de informação que dê apoio às tomadas de decisão para um desenvolvimento sustentável das áreas urbanas. Segundo Heilig (1995), citado por Kai, *et al.* (2007), a detecção precisa e atempada da mudança das características da superfície terrestre é essencial para o entendimento das relações e interações entre o Homem e o meio natural, com o intuito de promover a melhor decisão.

A tecnologia associada à DR tem uma aplicabilidade vasta, sendo cada vez mais frequente o seu uso para a produção de informação urbana. Como referem Weng e Quattrochi (2006), o avanço tecnológico aliado às necessidades de recolha de informação sobre áreas urbanas colocam a DR no centro da tecnologia geoespacial.

A tecnologia dos satélites usados na gestão territorial tem vindo a ser amplamente desenvolvida ao longo dos anos, incrementando a qualidade das imagens obtidas, permitindo-nos um melhor visionamento da informação da superfície terrestre, nomeadamente devido à crescente resolução espacial e espectral. O interesse sobre este tipo de imagens tem vindo a aumentar em vários campos de aplicação, tanto ao nível científico, como comercial. As primeiras imagens de satélite de alta resolução ficaram disponíveis foi em 1999, com o lançamento do satélite IKONOS; primeiro satélite civil com a capacidade de registar imagens com um metro de resolução espacial na banda do pancromático (Brovelli *et al.*, 2008). Outros satélites com características semelhantes foram lançados em seguida, nomeadamente: *EROS-A* (1.8m) e *EROS-B* (0.7m), *Quickbird* (0.61m), *WorldView-1* e *2* (0.5m), entre outros.

Segundo Amato *et al.*, (2004), até à data, estes satélites surgem como uma alternativa, aos ortofotomapas até a uma escala de 1:5.000. Santos *et al.*, (2010) referem que em Portugal, a produção cartográfica de pequena escala é morosa e dispendiosa, por ser resultante da edição manual sobre ortofotomapas. Os autores mencionam, também, que a actualização da informação geográfica e produção deste tipo de mapas é lenta limitando o seu uso na gestão territorial.

A crescente resolução temporal e espacial dos satélites de observação da Terra, tem determinado o registo sistemático do coberto do solo, nomeadamente, as alterações sucessivas que ocorrem nas áreas urbanas (Brovelli *et al.*, 2008). Contudo, o detalhe que uma imagem de alta resolução nos fornece obriga também ao desenvolvimento de procedimentos alternativos de classificação de dados. A abordagem convencional de classificação de imagem, classificação Pixel a Pixel comumente usada pela comunidade científica, e desenvolvida sobretudo nos anos 70, revela-se, em determinadas circunstâncias geográficas, inadequada no processamento de imagens de alta resolução, pois ignora o conceito espacial, estando muito associada à assinatura espectral do pixel. Neste tipo de imagens, existe uma grande probabilidade dos pixels vizinhos de um determinado pixel pertencerem de igual forma à mesma classe (Blaschke e Strobl, 2001); mesmo tendo comportamentos espectrais distintos. Neste sentido, é frequente existirem classes tematicamente

distintas que se assemelham no seu comportamento espectral e, por isso, a classificação requer a introdução de outro tipo de variáveis (Chuvieco, 2002).

Neste âmbito, surge a necessidade de introduzir uma diferente abordagem de classificação, que mitigue este tipo de dificuldades. A classificação *Orientada ao Objecto* assume-se como uma alternativa; já que apresenta, pelo menos no plano teórico, um grande potencial na capacidade de extrair informação automaticamente através de imagens de alta resolução (Ma *et al.*, 2009). Os métodos de classificação *Orientados ao Objecto*, ao contrário dos de aproximação ao pixel, que se cingem à sua assinatura espectral associada a cada pixel, baseiam-se em segmentar a imagem em polígonos com valores digitais homogéneos, e classificá-los com métodos que têm em conta: os valores espectrais, textura, contexto espacial em que se insere cada píxel, contexto temporal, verificação da assinatura espectral para outras imagens do mesmo local em diferentes datas (Chuvieco, 2002).

Lucieer, Fisher e Stein (2005) referem que existem novas possibilidades para processamento e análise de imagens satélite, em especial para as de muito alta resolução. Os novos métodos de classificação da imagem, surgem no interesse de se desenvolver e aperfeiçoar técnicas de processamento de imagem, que nos permitam de forma célere e assertiva monitorizar os objectos/fenómenos em causa. Em oposição aos métodos mais convencionais que tratam a imagem como um conjunto de pixels que são classificados individualmente, segundo as suas propriedades espectrais, na abordagem ao objecto, os pixels são primeiramente agrupados e só depois classificados de acordo não só com a sua assinatura espectral, mas também segundo a forma, o tamanho e a relação espacial com objectos vizinhos (Bhaskaran, S., 2010). Neste sentido, obtêm-se objectos que apresentam no seu interior pixels com diferentes reflectâncias. Como referem Zhou e Troy (2008), um exemplo deste tipo de abordagem é a copa de uma árvore poder ser identificada como uma unidade apesar da heterogeneidade dos pixels que a constituem.

A presente dissertação de mestrado tem por objectivo geral o processamento de imagens de alta resolução espacial e espectral, usando para tal uma imagem *WorldView-2*. Diferentes abordagens de classificação são ensaiadas, com o fim de examinar o seu desempenho na classificação de imagens de uma área urbana. A cena

eleita para o estudo de caso, recai sobre uma zona da cidade de Lisboa, que devido à sua heterogeneidade permite um estudo mais amplo e diversificado, na aplicação de diferentes métodos de classificação. A dissertação teve ainda por objectivo dar continuidade a uma série de trabalhos realizados pelas equipas de investigação do e-GEO-FCSH; assim como de outras equipas internacionais em matéria de processamento digital de imagens de satélite aplicadas a áreas urbanas.

Numa primeira fase, procedeu-se à classificação da imagem com aproximação ao Pixel, de forma supervisionada, pelo algoritmo *random forests*. Numa segunda fase, executou-se a Segmentação da imagem, pelo *software IDRISI Taiga*, e depois por Objectos, pelo *eCognition 8.0*. Posteriormente, os segmentos e os objectos resultantes de cada processamento foram classificados pelo algoritmo *nearest neighbor*. Finalmente, foi realizada uma avaliação da exactidão para as diferentes abordagens propostas.

A tese compreende um total de cinco capítulos, que intentam expor o presente estudo, mostrando qual a sua relevância na actualidade das ciências geográficas, mais especificamente no âmbito da DR, e a sua importância na gestão do território. No primeiro capítulo, fazemos a formulação do problema e qual o princípio metodológico que vai servir de fio condutor à presente dissertação, bem como a apresentação do estudo de caso seleccionado sobre o qual se executam as diferentes classificações. Neste capítulo é também realizado o estado da arte sobre o que já se tem feito sobre o processamento e classificações de imagens satélite de alta resolução em meio urbano. No segundo capítulo, faz-se uma explanação teórica que nos conduz a uma descrição de cada classificador, bem como dos algoritmos de segmentação de imagem operacionalizados dos diferentes *softwares*. No capítulo terceiro apresenta-se uma proposta uma nomenclatura que pretende representar os elementos urbanos da paisagem de parte das “Avenidas Novas” da cidade de Lisboa. Segue-se a exposição sobre a metodologia aplicada em cada ensaio. No capítulo V figuram as classificações resultantes das diferentes abordagens. O capítulo discute os resultados obtidos, recorrendo-se à apresentação das imagens classificadas, à análise comparada da exactidão, através de matrizes de confusão, estimando-se a exactidão global, bem como o Índice de concordância Kappa para cada resultado. Na conclusão, é feita uma

análise geral do trabalho executado, e de como este pode desencadear outras ideias que podem ser exploradas, com o intuito de se aprofundar o conhecimento da riqueza de imagens de alta resolução e qual a melhor forma de se trabalhar com as mesmas.

1.2. Problema, Objecto e Metodologia

A classificação de imagens de alta resolução sobre áreas urbanas é complexa. A forma e morfologia dos elementos que compõem as áreas urbanas representam um desafio enorme, facto confirmado pela literatura sobre a matéria e pela experimentação realizada. Vários são os problemas que se colocam na classificação de dados de alta resolução, espacial e espectralmente, como a usada para o presente estudo. Por exemplo, a vegetação arbórea assume uma grande variabilidade espectral, a copa das árvores é representada por pixels que individualmente assumem assinaturas espectrais distintas. Outros desafios são colocados aos algoritmos de classificação e segmentação, nomeadamente a separação e posterior identificação de elementos que se assemelham na sua assinatura espectral, como a água e a sombra. Outro exemplo é o ‘pavimento betuminoso’ e os ‘Edifícios com cobertura de betão’, ou até mesmo outras ocupações do solo menos frequentes, mas existentes na cidade de Lisboa, como os campos de jogos com pavimento de betão. Num caso oposto, ao anteriormente nomeado, também difícil, é o reconhecimento de classes compostas por unidades com diferentes assinaturas espectrais. Os ‘Edifícios com cobertura de betão’, antes citados, são muito desiguais entre si; o desenho e acabamentos do seu topo confere-lhes diversas formas e uma grande variabilidade espectral; situação semelhante ocorre com outro tipo de edifícios, com coberturas de materiais diferentes.

A assinatura espectral, no processamento de imagens satélite com alta resolução, assume-se insuficiente para a distinção das diferentes classes, tendo que ser combinada com outro tipo de critérios, como a forma e a textura, que por si só também são incapazes de resolver a questão. Várias são os segmentos da imagem que se assemelham em forma e textura, mas que apresentam assinaturas espectrais distintas. Por exemplo, a sombra de um edifício pode-se assumir com uma forma rectangular, de textura uniforme, idêntica à de um campo de jogos ou de um edifício.

A presente dissertação leva a cabo o processamento e classificação de um mesmo *subset* de imagem *WorldView-2*, sobre uma zona de Lisboa, por diferentes abordagens. A imagem usada neste estudo apresenta não apenas uma alta resolução espacial, mas também uma alta resolução espectral.

A primeira tarefa da metodologia passa por fazer uma análise visual exaustiva da área de estudo, com o fim de aferir quais os elementos urbanos presentes e definir as classes que os irão agrupar e caracterizar. Uma análise não supervisionada, pelo algoritmo *IsoData*, é realizada com o intuito de auxiliar a figuração da nomenclatura a propor-se e a ser seguida na classificação das imagens pelas diferentes abordagens.

O que se propõe é examinar a capacidade de cada abordagem para classificar o uso do solo e cobertura da superfície deste espaço urbano. As abordagens ensaiadas são as seguintes:

1. Classificação *pixel a pixel*, de forma supervisionada, com o algoritmo *random forests*.
2. Classificação *orientada por segmentos*, gerados no *software IDRISI Taiga*, e posteriormente classificada pelo algoritmo *nearest neighbor*.
3. Classificação combinada, que conjuga o resultado obtido pela classificação *pixel a pixel* e reagrupa os pixels pelos segmentos gerados no *software IDRISI Taiga*.
4. Classificação *orientada por objectos*, obtidos no *software eCognition 8.0*, e seguidamente classificados pelo algoritmo *nearest neighbor*.

Após realizadas as diferentes classificações, efectua-se uma análise de exactidão, através de matrizes de confusão onde se calcula os erros de omissão e comissão para cada classe, bem como a exactidão no utilizador e no produtor. O índice de concordância Kappa será também aferido para cada abordagem. Este processo irá ser efectuado para os diferentes níveis da nomenclatura proposta.

Esta análise irá ser efectuada sobre outros dois ensaios de classificação que resultam de pequenas alterações às abordagens anteriormente listadas em 3 e 4, com o intuito de verificar se a análise de exactidão e índice de concordância Kappa conseguem ser melhorados.

O *software* usado neste processamento é: *ENVI4.7.*, *IDRISI Taiga* e *eCognition 8.0* no processamento digital, auxiliado ainda por outros programas complementares como *R* e *ArcGIS 10*.

I.3. ÁREA DE ESTUDO

A área de estudo (Figura 1) corresponde à área administrativa da Freguesia do Campo Grande e parte das freguesias limítrofes. Nesta área urbana há uma ampla variedade de assinaturas espectrais resultantes, naturalmente, da diversidade de ocupações do solo urbano: vegetação do Jardim do Campo Grande, que se insere no planalto Norte de Lisboa, zonas relvadas da Cidade Universitária, diferentes tipos de edificação, como o Bairro de Alvalade, e outro tipo de estruturas como a Praça de Touros do Campo Pequeno. Nesta área urbana, temos áreas com diversificadas densidades de construção, que alternam com espaços de recreio, espaços abertos, e com a rede de arruamentos; sendo ainda passível de identificar corpos de água.




Figura 1 – Enquadramento Área de Estudo

I.4. Síntese do Estado da Arte

As imagens obtidas por Detecção Remota são, convencionalmente, processadas ao nível do Pixel; regra geral de forma supervisionada, onde cada pixel é alocado a uma determinada classe. De forma sucinta, “o objectivo global do procedimento de classificação de imagem é classificar automaticamente todos os pixels de uma imagem em classes de cobertura terrestre ou temas” (Lillesand e Kiefer, 2000). No entanto, esta abordagem apresenta limitações, pois a assinatura espectral de um pixel não é por si só suficiente para que se obtenham bons resultados na classificação das imagens de alta resolução. ChenJian e XiangLi, 2009, referem que os métodos tradicionais de classificação de imagem não conseguem tirar partido da informação que constitui as imagens de alta resolução, como a estrutura geométrica e a textura dos elementos da superfície terrestre que estas registam.

O aparecimento de satélites que possibilitam a obtenção de imagens de alta resolução espacial, espectral e temporal, conduziu, segundo Santos *et al.* (2010), a propostas de “novos paradigmas de classificação, que pretendem replicar a identificação dos elementos” da paisagem “de forma análoga à interpretação realizada pelo cérebro humano”.

A classificação *orientada por segmentos e por objectos* emerge, neste âmbito, como uma alternativa de extracção das ocupações do solo, onde os pixels são primeiramente agrupados em objectos e só depois classificados. Segundo ChenJian e XiangLi, 2009, “a unidade mais pequena da imagem deixa de ser um pixel, mas um objecto.” Esta nova abordagem tem sido alvo de vários estudos realizados para as áreas urbanas; contudo, ainda levanta várias questões que continuam abertas a discussão. Os artigos publicados na literatura internacional revelam diferentes tipos de ensaio, como o presente, que pretendem demonstrar a mais-valia da introdução da classificação da imagem *orientada por objectos* ensaiando-a e contrapondo-a, ou até mesmo combinando-a, com a abordagem convencional *pixel a pixel*.

A classificação de imagens de alta resolução sobre áreas predominantemente urbanas é um desafio, pois a similaridade espectral dos elementos urbanos indica o quão difícil será distinguir algumas classes de uso do solo, como por exemplo o pavimento betuminoso, de ‘Edifícios com cobertura de betão’ e áreas de

parqueamento. A abordagem ao objecto poderá representar uma mais-valia, na distinção destes elementos, contudo o procedimento poderá por si só não ser suficiente. Pinho *et al.* (2012) mencionam as dificuldades encontradas sobre a classificação de uma área urbana, com uma imagem de alta resolução IKONOS II, pela abordagem ao objecto. Estes investigadores entendem que a análise das classes urbanas, com este tipo de procedimento, mesmo que vantajoso, é morosa e complexa devido às dificuldades de processamento relacionadas com a segmentação de imagens, que devolve um grande número de objectos para ser classificado.

Salehi, *et al.* (2012) apontam para a importância do uso de informação vectorial temática aquando o processamento (Bases de dados geográficos oficiais existentes em algumas cidades). Estes autores defendem a incorporação de dados como LiDAR, modelos digitais do terreno, e até mesmo dados extraídos primeiramente da imagem, como a textura, o contexto e a morfologia (assunto alvo, este último, de outras equipas de investigação). Estudos elaborados pelas equipas de investigação do e-GEO-FCSH, por vezes em parceria com o Laboratório Nacional de Engenharia Civil, utilizam esta abordagem na extracção de elementos urbanos.

O grupo de investigação MGCOT do e-Geo da FCSH, tem trabalhado no sentido de encontrar um procedimento que consiga ultrapassar os entraves existentes na actualização de cartografia de grande escala, que geralmente é dispendiosa, morosa e inadequada face às necessidades exigidas para a gestão municipal (Santos, *et al.*, 2010). A cidade de Lisboa tem sido alvo de estudo com imagens de alta resolução Quickbird (2.4m nas bandas espectrais e 0.6m na banda do pancromático), com o intuito de se descobrir um método expedito da extracção de elementos urbanos. Este grupo propõe o uso de dados LiDAR (*Light Detection and Ranging*), como informação complementar para detectar e identificar alterações existentes sobre cartografia mais antiga (Santos, *et al.*, 2010); estes dados ajudam na separação de objectos com grande semelhança espectral, pois acrescenta mais uma dimensão à imagem, como já foi aludido anteriormente. Um destes estudos datado de 2010, de Santos *et al.*, intitulado “*Extracção de Edifícios em áreas urbanas densas com imagens Quickbird e dados LiDAR*”, usa o *software Feature Analyst* para ArcGIS na individualização dos elementos. Uma nomenclatura hierarquizada é proposta em dois níveis, com um número máximo

de cinco classes, das quais fazem parte três alusivas a edifícios com diferentes tipos de cobertura, e outras três referentes a eixos de via, outras superfícies betuminosas e a vegetação. Neste ensaio consegue-se obter uma análise de exactidão na ordem dos 73 %, para grupo dos edifícios (Santos, *et al.*, 2010). Noutro estudo semelhante através do qual se pretende, como indica o título, aferir a “Extracção de Arruamentos em áreas urbanas a partir de imagens de satélite com alta resolução espacial e dados LiDAR” (Freire *et al.*, 2011), o melhor valor conseguido de exactidão global é na ordem dos 54.7%. Este facto indica a dificuldade dos métodos desenvolvidos em atingir exactidão elevada. Outro ponto a referir é que a avaliação do erro foi feita sobre informação de referência obtida por análise visual de imagem efectuada por um operador independente.

Bhaskaran, *et al.* (2010), realiza a classificação de uma área urbana, em Nova Iorque, a partir de uma imagem do satélite IKONOS, combinando a classificação pixel a pixel, com uma classificação *orientada por objectos*. A classificação tem início com aproximação ao pixel, sendo classificada pelo algoritmo Máxima Verosimilhança, para 7 classes urbanas. Foi realizada uma análise de exactidão global, através de uma imagem de referência, onde se verificou superior a 80 % em 5 das classes, e menor valor, mas ainda superior a 70% em duas das classes, representativas da vegetação e dos ‘Edifícios com cobertura metálica’. Para estas duas classes efectuaram uma classificação *orientada por objectos*, a fim de aumentarem a exactidão, o que surtiu efeito, melhorando na ordem dos 10% para cada uma. Os autores recomendam uma abordagem de classificação combinada.

Os algoritmos de segmentação da imagem são importantes para a obtenção de bons resultados aquando a classificação. O algoritmo *multiresolution* do *eCognition 8.0*, nas suas várias versões, é usado em vários estudos, em detrimento de outros muito dependentes das características espectrais da imagem, que apresentam dificuldades em sua execução a diferentes escalas, e estando a sua aplicabilidade limitada na classificação de uso do solo sobre a malha urbana (Carleer *et al.*, 2005). Van der Sante, *et al.* (2003) referem que este algoritmo não só considera as características espectrais da imagem, mas também outro tipo de propriedades, como a forma, a estrutura, o tamanho e o contexto. O seu método operacional passa por individualizar os pixels

para depois agrupá-los em objectos maiores (Frauman e Wolff, 2005). A sua aplicabilidade em áreas urbanas torna-se vantajosa, na medida que consegue lidar com a heterogeneidade espectral destas áreas.

Pinho *et al.* (2012), duma equipa de investigação do INPE (instituto Nacional de Pesquisas Espaciais), realizaram um estudo sobre uma imagem de alta resolução IKONOS II, sobre a cidade de São José dos Campos, com o intuito de ensaiar um método de classificação *orientada por objectos* sobre a malha urbana. O procedimento é realizado no *software eCognition 8.0*, onde se executa, em cada nível da hierarquia da nomenclatura proposta, a segmentação da imagem pelo algoritmo *multiresolution*; os dados são explorados com intuito de se encontrar padrões e regras de associação entre as unidades da imagem. O processo é hierarquizado por níveis; em cada nível combinam a melhor optimização dos parâmetros disponibilizados pelo *eCognition 8.0*., aquando a segmentação da imagem, fazendo-os variar a escala, a relevância a dar à forma e a textura. A análise de exactidão alcançada é na ordem dos 72%, sobre a classificação da imagem por 11 classes; nomeadamente cinco classes de edifícios distintos em função do tipo de cobertura: betão claro, “médio” e escuro; cerâmica; e metálica. As outras classes correspondem ao solo exposto, ao pavimento betuminoso, à sombra, aos corpos de água, e à vegetação arbórea e herbácea.

Outro ponto relevante é que a classificação *orientada por objectos* revela um bom desempenho na extracção de informação a partir de imagens de média e alta resolução espacial. AN *et al.* (2007) assinalam que o método operado sobre uma imagem Landsat, com o algoritmo *multiresolution* no *eCognition 8.0*, mostra bons resultados na classificação de uma área na ordem dos 400 km², onde somente se pretende aferir a evolução do tecido urbano. Neste caso, o valor de exactidão global atinge os 85 %, enquanto o índice de concordância Kappa 0.79. Este tipo de análise é também válido, e de grande interesse, no sentido de serem dados mais acessíveis, com resolução temporal muito boa, cobrindo vastas áreas, permitindo observar a dinâmica geral das paisagens urbanas. Outro estudo de características semelhantes, e procedimento idêntico, onde se ensaia o algoritmo *multiresolution*, para diferentes escalas e combinações de parâmetros de forma e textura, é realizado para uma cidade chinesa de pequena dimensão e sua área envolvente, com uma imagem ASTER, de

resolução espacial de 15 m. Neste caso, consegue-se dividir em sete classes o uso do solo, em classes generalistas, como por exemplo áreas cultivadas, floresta e área urbana. Nesta classificação, ChenJian e XiangLi (2009) conseguem apurar uma exactidão global de 90% e um Kappa perto dos 0.9. Os mesmos ensaiam um procedimento de classificação orientado ao pixel, onde as métricas do estudo de erro decrescem na ordem dos 30%.

A dimensão das áreas de treino é outra questão que se coloca aquando a classificação de imagens de alta resolução espectral. Lillesand e Kiefer (2000) sugerem que a dimensão das áreas de treino deve corresponder a dez vezes o número das bandas espectrais disponíveis. Este valor tem servido de referência; segundo Niel, *et.al.* (2005), o número de áreas de treino deve ser entre dez a trinta vezes o número de bandas da imagem em causa. Esta regra é apenas considerada como boa prática, nunca tendo sido provado efectivamente qual a dimensão que as áreas de treino devem ter para cada dimensionalidade de dados. Os mesmos autores referem ainda que esta regra é aplicada consensualmente sem questionar qual a sua relevância na complexidade do problema de separação das classes. Hand (1981), Hughes (1968), Pal e Mather (2003), citados por Niel, *et.al.* (2005), avançam com um paradigma conhecido pela “maldição da dimensionalidade”, que explica que o valor de exactidão tende a aumentar com o número de variáveis, neste caso as bandas espectrais, mas com um limite, a partir do qual o valor de exactidão decresce. A actualização desta regra de ouro, por uma regra heurística, também consensualmente aceite, enuncia que o número das áreas de treino para alcançar certo valor de exactidão, vai depender sobretudo do nível de discriminação pretendido, tendo em conta, o tipo de dados disponíveis para a área de estudo eleita e suas características intrínsecas, bem como o nível de classificação ambicionado (Niel, *et.al.*, 2005).

A pesquisa bibliográfica, quer sobre a classificação de imagens de alta resolução sobre meio urbano, quer especificamente sobre a abordagem de classificação *orientada por objectos*, não devolveu artigos que comparem as diferentes abordagens de aproximação aos elementos urbanos, entre os *softwares* IDRISI Taiga e eCognition 8.0, razão pela qual se julga justificável o trabalho desenvolvido nesta dissertação.

II.1. A Nomenclatura

A classificação de uma imagem pode ser realizada segundo duas abordagens: a) *pixel a pixel*, supervisionada e não supervisionada; e b) as *orientadas por segmentos e por objectos*.

Contudo, todas se iniciam, com excepção da classificação não supervisionada, pela definição de uma nomenclatura utilizada para categorizar as unidades a classificar em cada procedimento de agrupamento de dados espectrais.

A selecção das áreas de treino, segundo uma nomenclatura proposta é fundamental para o início de qualquer processo de mapeamento, pois segundo Congalton e Green (1999) este procedimento cria ordem no caos e reduz o número total de unidades da imagem, organizando-as por classes. Os mesmos autores referem, que um processo de classificação rigoroso deve definir *à priori* uma nomenclatura, pois caso contrário poderá ter implicações na análise de exactidão global, aquando a amostragem dos pontos de referência.

A decisão da nomenclatura deve ter dois pontos seguros de base. O primeiro é uma designação correcta e ímpar para cada classe a distinguir; no segundo, é necessário eleger uma chave de identificação das diferentes classes e se possível de forma hierárquica. Nenhum processo de classificação supervisionado deve ter início antes de se analisar exaustivamente a imagem a classificar, encontrando quais os problemas que poderão ocorrer com a nomenclatura proposta de base, “optimizando-a”. Esta deve ser mutuamente exaustiva, o que requiere que cada área mapeada confira as características de uma só classe; bem como deve ser totalmente exaustiva, ou seja, cada unidade da imagem deve ser capaz de ser identificada por uma classe (Congalton e Green, 1999).

Os factores descritos no parágrafo anterior, dão apoio à ideia de se realizar uma análise exploratória, como a classificação *não supervisionada*, com o fim de se apurar qual o número e o tipo de classes a categorizar no processo de classificação.

O nível de especificação de uma nomenclatura influencia o processo de avaliação da exactidão global, quanto maior o nível de pormenor, mais exaustivo e moroso irá ser. A hierarquização da nomenclatura por níveis pode ser vantajosa na medida que permite realizar a análise de exactidão também por níveis, salvaguardando o caso de uma classe que revele ser de difícil extracção e categorização poder ser agrupada noutra de nível anterior (Congalton e Green, 1999). Este ponto é muito importante, aquando a classificação de imagens de alta resolução sobre uma área urbana, onde os elementos são muito diversificados.

II.2. Classificação *Pixel a Pixel*

O sucesso de uma classificação *pixel a pixel* resume-se à capacidade do classificador identificar, de forma fiável, as diferentes assinaturas espectrais extraídas a partir de um determinado conjunto de bandas espectrais (Eastman, 2009).

Vários são os métodos de classificação existentes, sendo que cada um possa revelar um nível maior ou menor de optimização, dependendo dos dados base, bem como quais os objectivos específicos a que se propõe. Porém, todos devem respeitar as seguintes premissas: exactidão; replicação igual, mesmo quando efectuada por outros utilizadores, desde que as variáveis iniciais se mantenham; robustez, garantir que o resultado se mantenha, mesmo havendo pequenas alterações das variáveis iniciais; exaustivo, que tenha em conta toda a área de estudo; e objectivo, que o intérprete seja assertivo e imparcial (Cihlar, 1998). Todavia, neste último princípio tem de se ter em conta que a decisão do intérprete é por vezes fundamental na discriminação de diferentes classes, devido à capacidade de distinção do olho humano para reconhecer diferentes classes na imagem.

A classificação de imagem *pixel a pixel* pode ser realizada segundo duas abordagens: supervisionada ou não supervisionada. O que distingue os dois processos é a forma como são obtidas as estatísticas das áreas de treino. Resumidamente, na classificação supervisionada, as áreas de treino disponibilizadas ao classificador são dadas pelo utilizador, com conhecimento prévio da área de estudo. Já na não supervisionada, o classificador procede a uma busca automática de grupos de valores

digitais homogêneos dentro da imagem. Aqui a única tarefa do analista, é de fazer corresponder as classes aos objectos reais (Chuvieco, 2002).

II.2.1. Classificação Não Supervisionada

A classificação não supervisionada é conhecida pelo seu carácter exploratório, ao agrupar de forma automática grupos espectrais, sem o auxílio de classes de treino; permite de forma breve, ao operador, identificar quantas classes são estatisticamente separáveis a partir dos dados disponíveis (Mather, 2005). O operador, no fim desta abordagem, faz corresponder uma classe espectral a uma classe temática (Figura 2), verificando, no caso de existirem, a presença de classes puras e/ou “mistas”.




Figura 2 – Correspondência entre classes

Fonte: Chuvieco (2002) (adapt.)

A obtenção de cada grupo espectral inicia-se segundo o critério de similariedade entre os pixels, com recurso a condições de agrupamento (Chuvieco, 2002). Os classificadores não supervisionados, agrupam os dados tendo em conta apenas a sua informação numérica. Os mais utilizados são *K-mean* e *IsoData*.

O *k-mean*, intenta classificar os pixels segundo padrões espectrais uniformes, através de um processo iterativo utilizando a distância euclidiana entre dois pixels. A sua classificação será tanto melhor, quanto o agrupamento dos pixels (Mather, 2005). A classificação termina aquando forem executadas o número de interações

desejadas, valor definido inicialmente pelo operador; ou antes, caso a percentagem de número de pixels permitidos a alternarem entre classes, aquando as interações, seja inferior ao definido no início do processo.

O *IsoData*, tem também várias fases de execução, onde primeiro identifica padrões para o número de classes indicado pelo operador, determinando o centro para cada uma, e classifica os pixels da imagem tendo em conta o centro da classe que está mais próxima ao mesmo. Em seguida, determina-se novamente, o centro das classes, tendo em conta os valores de todos os pixels incorporados na fase anterior, e parâmetros de distância mínima entre classes espectrais, número mínimo de pixels em cada, variância máxima interna e número máximo de classes. Os pixels são novamente alocados a cada classe, segundo a distância mais curta ao centro de cada classe; o processo repete-se até a um número máximo de iterações possíveis determinado de início pelo operador, ou aquando o recálculo dos centros de classe for quase idêntico ao anterior, o que indica que se atingiu o melhor agrupamento de pixels possível (Chuvienco, 2002).

II.2.2. Classificação Supervisionada

Na classificação supervisionada, o processamento tem início com a definição das assinatura espectrais para cada classe, com a atribuição das áreas de treino; em seguida, é feita a classificação da imagem, com a agregação dos pixels e sua posterior alocação a cada classe. A classificação é controlada pelo operador que desta forma supervisionada a categorização de cada classe.

Lillesand e Kiefer (2000), referem as três etapas de uma classificação supervisionada. Numa primeira fase, o analista identifica áreas de treino representativas e desenvolve uma descrição numérica da assinatura espectral, para cada classe de interesse. Em seguida, na etapa de classificação, cada pixel irá ser alocado à classe com que mais se assemelha. Por fim, depois de classificada a imagem, esta poderá ter diferentes usos, como por exemplo produzir cartografia temática. A figura 3 ilustra resumidamente os passos deste processamento.




Figura 3 – Passos de uma classificação supervisionada

Fonte: Lillesand, T. and Kiefer, R. (2000) (adapt.)

II.3. Classificação *Orientada por Segmentos e por Objectos*

A classificação de imagem *orientada por objectos* inicia-se com a segmentação da imagem, dividindo-a em regiões homogêneas de pixels, que ambicionam espelhar objectos reais. A individualização dos segmentos/objectos tem em conta não só a informação espectral dos pixels, mas também os seus atributos topológicos e espaciais (Bhaskaran, S., 2010).




Figura 4 – Passos da segmentação da imagem e posterior classificação

A segmentação tem em conta diferentes tipos de variáveis, consoante o *software* que a realiza. Na presente dissertação irão ser testados e comparados, os algoritmos de segmentação provenientes do *IDRISI Taiga* e do *eCognition 8.0*, bem como a exactidão dos resultados dos diferentes métodos de classificação.

II.3.1. Classificação *Orientada por Segmentos*

A classificação *orientada por segmentos*, agrupa os pixels adjacentes da imagem em segmentos de acordo com a sua similaridade espectral, sendo que a circunscrição da imagem em 'objectos' é efectuada com base na variância dos dados digitais da imagem (Eastman, 2009).

O objectivo geral do processo de segmentação, e causa, é agrupar as unidades da imagem, definidas pelos pixels, em outras mais significativas para a sua interpretação, facilitando o processo de classificação; idealizando um contributo positivo para melhores valores de exactidão global.

O processo de classificação por segmentos, em *IDRISI Taiga*, segue uma metodologia híbrida, que combina uma abordagem de aproximação ao pixel com uma classificação agrupada por segmentos (Eastman, 2009). O módulo proposto pelo *IDRISI Taiga* ocorre em 4 etapas:

1. Segmentação da Imagem (Segmentation) agrupa pixels adjacentes que compartilhem de semelhante homogeneidade espectral, considerando apenas parâmetros radiométricos.
2. Atribuição das Áreas de Treino (Segtrain) sobre os segmentos criados na etapa anterior; parte destes são selecionados para representar cada classe de interesse aquando a classificação da imagem.
3. Classificação da Imagem pixel a pixel, usando as áreas de treino atribuídas sobre os segmentos.
4. Aplicação de um algoritmo de Majoração (Segclass), procede à intersecção dos pixels classificados em (3.) pelos segmentos criados em (2.). A cada segmento é atribuída a classe cujos pixels se apresentam com maior frequência no seu interior.

Os parâmetros que podem ser manipulados, aquando o processamento segmentação de imagem, passam a ser descritos, em seguida:

1. O número e quais as bandas (layers) da imagem, e qual a significância de cada uma para o processamento de derivação da imagem de estudo.

2. Tamanho da janela de varrimento (Window width), desloca-se sobre toda a imagem, avaliando a similariedade espectral, verificando a variância existente dentro dos seus limites, atribuindo essa característica a cada pixel. A imagem resultante deste processamento, é uma média ponderada da variância atribuída a cada layer.
3. Proporção entre a média e o desvio padrão, a ser usada na avaliação da similariedade entre segmentos adjacentes.

No delineamento do contorno de regiões homogêneas de pixels, estas devem ter valores o mais aproximadamente possível de zero, demarcando-se dos pixels na linha fronteira das mesmas, que apresentam valores superiores.

4. Similariedade permitida/tolerada entre segmentos, definida por um número inteiro e positivo. O número de segmentos irá variar numa proporção inversa à tolerância, quanto maior for o valor desta, menor será o número de polígonos.

A segmentação inicia-se com a tradução da imagem original numa outra de variâncias; uma janela de varrimento desliza sobre toda a imagem, atribuindo um valor de variância a cada pixel. O produto final irá resultar da média das variâncias para todas as *layers*, ou seja, para todas as bandas espectrais que entram no processamento. A imagem é delineada pelo valor médio das variâncias; nas regiões onde os pixels são mais homogêneos, observa-se menor taxa de variância, enquanto na bordadura destas regiões mais homogeneizadas há um exponencial aumento da variância (Eastman, 2009).

Por fim, segmentos adjacentes são fundidos de acordo a sua similaridade espectral. Este processo é interactivo na medida que cada segmento é examinado individualmente, com o intuito de se identificar quais os segmentos vizinhos que mais se assemelham ao primeiro, e que cumpram os critérios para a sua fusão. Esta só ocorre se os segmentos forem adjacentes e mutuamente similares; bem como a diferença a diferença entre os valores de média e desvio padrão dos dois segmentos deve ser menor do que o limite especificado pelo operador, mencionado no anterior ponto 3. O processo termina na generalização dos segmentos orientada pela tolerância

de similaridade; quanto maior for o seu valor, menor será o número de segmentos de individualização da paisagem (Eastman, 2009).

II.3.2. Classificação *Orientada por Objectos*

O *eCognition 8.0* fornece uma panóplia de algoritmos de segmentação de imagem, de diferentes níveis de complexidade, com diferentes tipos de abordagem. Por exemplo, o *Chessboard* e o *Quadtree Base* dividem a imagem em objectos quadrados, embora com diferentes níveis de aperfeiçoamento; outros dividem a imagem consoante as assinaturas espectrais, por exemplo, em objectos escuros e brilhantes.

O algoritmo *multiresolution* é o eleito para a segmentação da imagem no estudo de caso pelo qual optámos. Método com uma abordagem *bottom-up*, inicia-se com a análise dos dados digitais da imagem para extrair os objectos; ao contrário das abordagens *up-bottom*, que primeiro descrevem qual o objecto a extrair e depois elaboram a melhor forma de o extrair.

O procedimento deste algoritmo consiste em, para um dado número de objectos de imagem, minimizar a heterogeneidade média, e maximizar a sua homogeneidade respectivamente. Ou seja, o processo tem início com o recorte da imagem em objectos individuais, de um só píxel, que são fundidos consecutivamente até que haja uma homogeneidade coesa entre os mesmos. Esta é decorrente da combinação da homogeneidade espectral e da semelhança da forma.

Por outras palavras, cada objecto, tendo por base o critério da homogeneidade, determina qual o melhor vizinho com o qual se deverá fundir, contudo se ao contrário não houver a mesma concordância, o objecto a que o primeiro se liga, desvia-o para um segundo objecto melhor vizinho. Este processo é repetido até que haja concordância mútua entre dois objectos vizinhos que acabam por se unir; norma replicada em toda a imagem até que seja possível manter o critério de homogeneidade.

A heterogeneidade permitida entre objectos é definida por dois parâmetros, considerados a variar no presente estudo. O primeiro é a *Scale*, determina qual o

máximo desvio padrão permitido no critério de homogeneidade; o aumento deste valor, diminui o número de objectos identificados, pois existirá maior agregação entre os mesmos. O outro parâmetro relaciona-se com a Cor e a Textura, qual o ênfase a atribuir a cada, partindo do princípio que estes se complementam e a sua soma ser igual a um.

O *eCognition 8.0* disponibiliza vários classificadores de imagem por objecto; uns com base em áreas de treino e outros no valor dos níveis digitais.

O classificador *nearest neighbor*, no *eCognition 8.0*, classifica com base em áreas de treino previamente atribuídas, bem como permite ainda escolher entre três opções de identificação espacial do objecto, são estas:

1. *Cor (C)*, classifica a imagem com base no valor digital de cada pixel.
2. *Cor e Textura (CT)*, adiciona ao método anterior as métricas para a textura de Haralick, por forma a obterem-se melhores resultados.
3. *Cor e Contexto (CC)*, adiciona ao valor digital de cada pixel, a conjuntura do mesmo a nível espacial. Permitindo separar áreas pelo contexto, que não seriam distinguidas caso estivessem isoladas. Por exemplo, veja-se a distinção da vegetação arbórea resinosa. As copas identificam-se pela sua assinatura espectral, na observação da imagem em falsa-cor (7/5/3), apresentam-se com um vermelho de tonalidade mais escura, por vezes mesmo perto de negro; por certo, um píxel isolado iria ser entendido talvez como pertencente a outra classe, onde a maioria dos pixels da mesma apresentassem semelhante comportamento espectral.

Vários são os parâmetros a variar em cada tipo de processamento de imagem contemplados por este estudo. A classificação *orientada por objectos* é também divergente, entre os dois *softwares* mencionados anteriormente. No *IDRISI Taiga*, a classificação segue uma metodologia híbrida, ou seja, a classificação final assenta numa imagem previamente classificada *pixel a pixel*, pelo classificador *nearest neighbor*, contudo delineada com a forma dos objectos. No *eCognition 8.0*, a classificação usa o mesmo classificador, contudo permite optar por um dos três

parâmetros de identificação espacial do objecto, nomeadamente a *Color*, *Color and texture*, e *Color and Mutual Embedding*.

Um dos pontos cruciais no processamento de imagens recai na escolha de um algoritmo de classificação apropriado, que fará a alocação dos pixels a determinada classe entre um conjunto pré-definido de classes (Blanzieri e Melgani, 2008).

II.4. Algoritmos de Classificação

II.4.1. Algoritmo *Random Forests*

O algoritmo *random forests* (RF) é um classificador estatístico muito eficaz e com vasta aplicação (Cutler, *et al.*, 2007), e eficiente na classificação de imagens em Detecção Remota (Gislanson, *et al.*, 2006). O procedimento geral passa por reunir um conjunto de métodos, que usa várias “árvores de decisão”, independentes e distribuídas de forma semelhante por vectores aleatórios segundo um padrão de entrada (Breiman, 2001), com a ambição de produzir uma classificação o mais exacta possível (Cutler, *et al.*, 2007).

As árvores de decisão seguem a estratégia de “dividir para conquistar”. A linha condutora do método passa por encontrar a solução para um problema a partir da sua consecutiva decomposição em subproblemas de menores dimensões (Reina, *et al.*, 2011). Contudo, revelam limitações por serem muito densos e serem incapazes de generalizar/agrupar os dados (Schroff, *et al.*, 2008), tornando o tratamento estatístico difícil a nível computacional. O RF surge no sentido de tentar ultrapassar esta questão e otimizar o processo, da seguinte forma: induzir aleatoriedade no treinamento das árvores de decisão, combinando o resultado num só classificador (Schroff, *et al.*, 2008). Ou seja, cada árvore sugere um voto para a classe que atribui ser a correcta, para um determinado padrão de entrada; sendo que a classificação final é determinada pelo maior número de votos reunidos pelas árvores alocados a cada classe (Gislanson, *et al.*, 2005).

No seu leque de vantagens, quando comparado com outro tipo de classificadores, temos: bons valores de exactidão global; novo método para a determinação da importância da variável; capacidade de modelar interacções complexas entre variáveis de diferentes indicadores; adaptabilidade para executar diferentes tipos de análises estatísticas, como classificações e regressões; e atribui valores quando inexistentes (Cutler, *et al.*, 2007).

A sua aplicação na classificação de imagens satélite é recomendável, pois inclui métricas de importância de variáveis e de similaridade entre pontos, que podem ser agrupados, em diferentes níveis, classificando toda a imagem por inteiro atribuindo valores quando inexistentes, produzindo um resultado gráfico (Cutler, *et al.*, 2007).

A sua capacidade de lidar com dados de grandes dimensões, com uma grande de uma grande variedade de características (no presente caso da tese, 8 bandas espectrais), torna o processo exequível, sem limitações computacionais (Gislason, *et al.*, 2005), tanto no tratamento das áreas de treino, como de classificação (Schroff, *et al.*, 2008). O software *R* adequa-se ao processamento do algoritmo RF, pois gere bem o processamento de algoritmos mais robustos e complexos do ponto de vista computacional.

II.4.2. Algoritmo *Nearest Neighbor*

O algoritmo de classificação *K-nearest neighbor*, é um classificador estatístico muito usado em Detecção Remota, não só pela sua simplicidade e facilidade de execução computacional, bem como por apresentar bons resultados aquando a classificação de imagens.

O argumento que o caracteriza é que assegura que o valor interpolado seja um dos valores originais, isto é, não calcula novos valores (Frank, R., 1982). Este classifica os objectos tendo em conta a distância a que estes encontram-se das áreas de treino assumidas. Cada unidade é classificada de acordo com o maior número de ‘votos’ existentes nas unidades vizinhas (Eastman, 2009).

O raciocínio deste algoritmo é procurar as áreas de treino mais próximas no espaço a cada unidade da imagem; seja esta um pixel, um segmento ou um objecto.

Quanto mais próxima esta for, maior será o grau de relação entre as mesmas. Este algoritmo tem boa performance a nível da classificação *orientada por objectos*, pois tem habilidade de correlacionar as classes por nível hierárquico (ChenJian e XiangLi, 2009).

Alguns pontos devem ser tomados em consideração aquando o processamento deste algoritmo, como o tamanho das áreas de treino, que pode ter um efeito negativo quando não são idênticas, em sua dimensão, para cada classe. A classificação com este algoritmo pode favorecer as classes com áreas de treino de tamanho maior. Outro factor a ter em conta é o valor atribuído a K, que pode ser limitativo para as áreas de treino de menores dimensões, pois pode afectar a decisão de alocar a uma unidade da imagem a certa classe (Eastman, 2009).

II.5. Análise de Exactidão

Em Detecção Remota, a análise de exactidão serve de designação da confrontação dos resultados obtidos por uma classificação da imagem com os dados geográficos de referência que são considerados como verdadeiros (Lillesand, *et al.*, 2008). A análise de exactidão sobre uma classificação é indispensável para que se possa fazer a análise do resultado, e avaliar se este preenche os requisitos a que se destina.

Segundo Foody (2009) “não existe um método universalmente aceite para a análise de exactidão”. O ideal seria realizar a avaliação sobre uma imagem inteiramente mapeada. Contudo, como na maior parte dos casos este método é impraticável opta-se por se fazer uma amostragem aleatória, para evitar o enviesamento da amostra e que esta seja representativa do todo.

O tamanho da amostragem deve ser tomado em consideração em estudos comparativos, pois pode ter efeito na precisão da análise de exactidão. Por exemplo, uma amostragem demasiado pequena pode ter consequências na detecção do erro resultante da classificação, quando este pode inclusive ser de grande dimensão (Foody, 2009).

Segundo Congalton e Green (1999) existe uma regra de boa prática que indica que o número de pontos de amostragem deve ser no mínimo de 50 para cada classe de uso do solo, e que esta deve ser aumentada para 75 ou até mesmo 100 quando o número de classes ultrapassa as doze.

A verificação dos resultados, em campo ou por dados geográficos auxiliares, é muito importante para que possa ter um registo sobre os erros da classificação e avaliar a sua qualidade.

Em relação, à avaliação da análise de exactidão sobre classificação de imagens *orientada por objectos*, ainda não há consenso, para os casos em que não há um mapa de referência inteiro para intersectar com a classificação. Alguns estudos realizam uma amostragem aleatória estratificada por classes como é o caso do estudo apresentado no estado da arte realizado por Pinho *et al.* (2012), que aleatoriamente lançaram sobre cada classe 100 pontos a serem aferidos. Já um dos estudos referidos, da equipa do e-Geo, Santos *et al.* (2010), referente à extracção de edifícios em áreas urbanas, optaram por desenhar um mapa de referência com a distribuição espacial da classe de interesse a avaliar a exactidão, ou seja, os Edifícios; ultrapassando assim da morosidade e dificuldade de criar um mapa inteiro de referência para toda a imagem.

II.5.1. Matriz de Confusão

A matriz de confusão, é uma ferramenta muito eficaz, em forma de tabela, que permite organizar e analisar qual a performance resultante da classificação de um determinado algoritmo.

A forma como se organiza (figura 5), de entrada dupla, permite confrontar o número de unidades (pixels ou polígonos) observadas e consideradas correctas, *versus* o mesmo número de unidades classificadas. Convencionalmente, as colunas representam as unidades observadas, as de referência, enquanto as linhas são referentes à classificação gerada (Congalton e Green, 1999).

A sua estrutura permite de forma rápida, calcular várias métricas, não só a análise de exactidão global (EG), mas também ao nível da classe; bem como calcular os

erros de comissão e de omissão; assim como a exactidão do produtor (EP) (*producers' accuracy*) e a exactidão do utilizador (EU) (*users' accuracy*).

		Unidades Observadas					
		Classe 1	Classe 2	Classe K	Total n_i	Erro de Comissão (%)	Exactidão do Produtor (%)
Unidades Classificadas	Classe 1	n_{11}	n_{12}	n_{1k}	n_{1+}	$(n_{1+}-n_{11})$ $/n_{1+}$ $\times 100\%$	100 - Erro de Comissão
	Classe 2	n_{21}	n_{22}	n_{2k}	n_{2+}	$(n_{2+}-n_{22})$ $/n_{2+}$ $\times 100\%$	100 - Erro de Comissão
	Classe K	n_{k1}	n_{k2}	n_{kk}	n_{k+}	$(n_{k+}-n_{kk})$ $/n_{k+}$ $\times 100\%$	100 - Erro de Comissão
Total n_{+j}		n_{+1}	n_{+2}	n_{+k}	n		
Erro de Omissão (%)		$(n_{+1}-n_{11})/$ (n_{+1}) $\times 100\%$	$(n_{+2}-n_{22})/$ (n_{+2}) $\times 100\%$	$(n_{+k}-n_{kk})/$ (n_{+k}) $\times 100\%$	$i = \text{n}^\circ \text{ de linhas}$ $j = \text{n}^\circ \text{ de colunas}$		
Exactidão do Utilizador (%)		100 - Erro de Omissão	100 - Erro de Omissão	100 - Erro de Omissão			

Figura 5 – Matriz de Confusão, sua organização e cálculo

Fonte: Congalton e Green (1999) (adapt.)

Na diagonal da tabela, estão representados as unidades que se encontram bem classificadas. A Análise da EG da classificação resulta da soma das unidades bem classificadas sobre número total de unidades. Este mesmo cálculo pode ser realizado ao nível de cada classe, tanto para as ditas Observadas, como para as Classificadas,

sendo representado como Erro de Omissão para as primeiras, e Erro de Comissão para as segundas. Valores estes utilizados para a estimativa da EU, e a EP, pela mesma ordem.

A EU indica qual a percentagem de unidades correctamente classificadas em relação às unidades observadas, tomadas como referência. Em oposição a esta métrica, perfazendo um total de 100 % quando somado com a primeira, temos o Erro de Omissão, que indica a percentagem de unidades classificadas que estão erradamente alocadas a outras classes (Congalton e Green, 1999).

A EP indica qual a percentagem de unidades correctamente classificadas em relação ao total das unidades classificadas no processamento. À luz da anterior, desta métrica também resulta o Erro de Comissão, que indica a percentagem de unidades classificadas numa categoria de forma errónea, ou seja, que deveriam estar atribuídas a outras classes (Congalton e Green, 1999).

II.5.2. Índice de Concordância Kappa

A disposição dos resultados da matriz de confusão permite aferir rapidamente o índice de concordância Kappa (Kappa).

O Kappa é uma medida de concordância que tem por base a diferença entre a actual concordância da matriz de confusão (ou seja, o número de unidades correctamente classificadas apresentadas na diagonal da matriz de confusão) e a possibilidade de concordância entre os totais das linhas e das colunas. Ou seja, apura qual a concordância existente os dados classificados e os dados de referência.

Matematicamente, o seu cálculo traduz-se pela seguintes expressão:

$$\text{Kappa} = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i.} \cdot n_{.i}}{n^2 - \sum_{i=1}^k n_{i.} \cdot n_{.i}}$$

Onde:

n = número de unidades amostradas;

k = número de classes;

i = nº de linhas e j = nº de colunas.

Segundo Congalton e Green (1999), o índice de concordância Kappa é usada como ferramenta de análise de exactidão em vários estudos publicados, sendo consesualmente um das técnicas que melhor afere a exactidão.

CAPÍTULO III. ENSAIOS DE CLASSIFICAÇÃO DE DADOS *WORLDVIEW-2*

O processamento da imagem ocorre em três etapas gerais, são estas:

- 1º, delimitação do Caso de Estudo e análise dos dados disponíveis;
- 2º, definição da Nomenclatura proposta;
- 3º, Ensaios de classificação.

Na tabela 1, vem esquematizada a simbologia que dá auxílio aquando a exposição dos diferentes ensaios.


Simbologia	Descrição
	Ficheiro <i>Raster</i> , representativo da imagem do estudo de caso.
	Operação da função a executar perante o processamento de imagem.
	Ficheiro Vectorial, referente à imagem do estudo de caso.
	Ficheiro de texto, com dados tabulados da imagem, geralmente resultantes dos <i>outputs</i> do processamento da imagem. Inclui nesta categoria também os <i>scripts</i> que são usados em alguns processamentos.
	Pequenos apontamentos sobre o processamento, como por exemplo parâmetros manipulados.

Tabela 1 – Simbologia esquematizada no processamento da Imagem

III.1. Dados e Caso de Estudo

A imagem usada na presente dissertação de mestrado é uma imagem de alta resolução, do satélite *WorldView-2*, capturada em Junho de 2010, em condições de céu limpo.

O Satélite comercial *WorldView-2*, posto em órbita no passado ano de 2009, a uma altitude de cerca de 770 km. Este fornece imagens de qualidade superior, dispondo de oito bandas multiespectrais (Figura 6) e uma resolução espacial de 2 metros; enquanto no modo pancromático oferece imagens com 50 cm de resolução espacial.




Figura 6 – Bandas do Satélite *WorldView-2*

As especificidades desta imagem multiespectral, do satélite *WorldView-2*, de alta resolução, permitem a distinção e classificação dos principais elementos que figuram numa paisagem dita urbana.

Uma breve análise é efectuada sobre as imagens do espectro electromagnético (figura 7 e tabela 2), a fim de se apurar qual o melhor contraste. Não só para facilitar a escolha das amostras de treino por parte do operador, bem como saber a sua relevância aquando o processo de segmentação de imagem pelo algoritmo provido pelo *IDRISI Taiga*. Neste processamento, é possível escolher qual o peso a dar a cada uma das bandas aquando a segmentação da imagem.




Figura 7 – Histograma com as 8 bandas do espectro electromagnético, presentes na imagem do estudo de caso

Covariance	Band 1	Band 2	Band 3	Band 4	Band 5	Band 6	Band 7	Band 8
Band 1	12746.908705	12663.383562	20628.526638	25314.453840	14544.936583	18942.032296	9507.490153	13397.666791
Band 2	12663.383562	13100.828580	21431.686183	25671.727953	15196.948644	19615.262339	10460.580259	14255.944417
Band 3	20628.526638	21431.686183	36498.818827	44502.704522	26069.217764	36187.956970	20209.659456	28379.536544
Band 4	25314.453840	25671.727953	44502.704522	59277.453580	34182.117669	48897.581451	25457.388762	37174.201448
Band 5	14544.936583	15196.948644	26069.217764	34182.117669	20696.666457	28262.297323	15251.663973	21376.547158
Band 6	18942.032296	19615.262339	36187.956970	48897.581451	28262.297323	52258.174941	34740.371522	51503.811894
Band 7	9507.490153	10460.580259	20209.659456	25457.388762	15251.663973	34740.371522	28655.159069	41857.441500
Band 8	13397.666791	14255.944417	28379.536544	37174.201448	21376.547158	51503.811894	41857.441500	63910.960393

Correlation	Band 1	Band 2	Band 3	Band 4	Band 5	Band 6	Band 7	Band 8
Band 1	1.000000	0.979937	0.956371	0.920919	0.895487	0.733917	0.497464	0.469396
Band 2	0.979937	1.000000	0.980094	0.921215	0.922905	0.749666	0.539890	0.492673
Band 3	0.956371	0.980094	1.000000	0.956758	0.948502	0.828605	0.624911	0.587595
Band 4	0.920919	0.921215	0.956758	1.000000	0.975897	0.878548	0.617686	0.603961
Band 5	0.895487	0.922905	0.948502	0.975897	1.000000	0.859370	0.626276	0.587760
Band 6	0.733917	0.749666	0.828605	0.878548	0.859370	1.000000	0.897751	0.891199
Band 7	0.497464	0.539890	0.624911	0.617686	0.626276	0.897751	1.000000	0.978101
Band 8	0.469396	0.492673	0.587595	0.603961	0.587760	0.891199	0.978101	1.000000

Tabela 2 – Valores de covariância e correlação entre bandas

Com base nestes dados, considera-se que as bandas 3, 5 e 7 apresentam a maior relação e grau de dependência linear, pois exibirem o menor nível de sobreposição dos valores digitais. Esta combinação de bandas fornece assim a combinação mais heterogénea e consequentemente uma imagem de maior contraste, factor de elevada importância no processamento de segmentação da imagem.

A delimitação da área do estudo de caso (Figura 8), recai sobre uma área heterogénea de Lisboa, ideal para se realizar os diversos ensaios de classificação da Imagem. Aqui poderá ser testado o comportamento algoritmos de classificação, sobre dados de muito altas resolução espacial e espectral.




Figura 8 – Delimitação da área do estudo de caso

A imagem usada está corrigida geometricamente e georreferenciada no *datum* WGS-84 e *Universal Transverse Mercator* zona 29. O estudo de caso está definido para as coordenadas geográficas 9°10'13.90"W, 38°45'37.56"N (4851184.0, 4290206.0) e apresenta uma extensão de cerca de 601 hectares.

III.2. Metodologia

A primeira tarefa do processo é fazer uma análise visual exaustiva da imagem, com o fim de aferir quais as classes que irão figurar no esquema de classificação.

Esta análise visual foi auxiliada por uma classificação não supervisionada, pelo algoritmo, *IsoData*, pelo factor de permitir classificar a imagem sem dar um número de classes exacto, deixando essa decisão ao classificador. Os parâmetros manipulados, neste processamento de imagem (Figura 9), foram o número mínimo e máximo de classes, neste caso 5 a 15 correspondentemente e o número de interacções permitidas, 2.




Figura 9 – Processamento da classificação não Supervisionada *IsoData*

A classificação não supervisionada, *pixel a pixel*, permite de forma célere e simples observar a assinatura espectral dos objectos presentes na imagem (Figura 10).



Figura 10 – Resultado da classificação não supervisionada *IsoData*

O resultado deste processamento é grosseiro e apenas indicativo de quantas classes se podem identificar com maior grau de facilidade. O algoritmo *IsoData* identifica um total de 10 classes. Contudo, observa-se que há algumas classes, que se objectiva separar e como a *Água* e o *Pavimento betuminoso* que se encontram mescladas, devido ao seu comportamento espectral ser idêntico.

III.2.1. Nomenclatura proposta de Classificação

A nomenclatura proposta pretende caracterizar os diferentes elementos da área urbana considerada, de forma hierarquizada indo do geral para o particular, organizada em 4 níveis de reconhecimento.

Um estudo de Pinho *et al.* (2012), sobre uma imagem *IKONOS II*, de uma área urbana, referido no estado da arte, serviu também de apoio ao delineamento das classes que a seguir se apresentam na Figura 11.

No primeiro nível separou-se todos os elementos urbanos dos não urbanos. Na classe do 'Urbano' maior parte dos elementos assemelham-se ou em forma ou na sua assinatura espectral. Estes são primeiramente agrupados no segundo nível por 'Edifícios e Infra-estruturas Desportivas' e por 'Eixos de Circulação', iniciando-se depois no nível 3 uma separação mais específica das classes que termina no nível quatro, com os 'Edifícios' diferenciados pelo tipo de cobertura e as 'Infra-estruturas desportivas' separadas por 'Pistas, campos de ténis e ciclovias' dos 'Relvados sintéticos e Campos de jogos com pavimento de betão'; bem como com os 'Eixos de circulação' divididos em 'Pavimentos betuminosos' dos 'Passeios e outras áreas pedonais'.

Na classe do 'Não Urbano', do primeiro nível, temos uma maior variabilidade entre os elementos que a constituem, não só em relação à sua assinatura espectral, bem como à sua forma. No segundo nível separa-se os elementos que são 'Vegetação' dos 'Não Vegetação', são estes o 'Solo Exposto', a 'Água' e a 'Sombra'. No terceiro nível ainda se faz a distinção entre o diferente tipo de 'Vegetação' presente, que culmina no nível 4 com a 'Vegetação Arbórea Resinosa', distinguida da 'Vegetação Arbórea Folhosa' e da 'Vegetação Herbácea'.

Uma chave de identificação (tabelas 3, 4, 5, 6 e 7) para cada classe do nível 4 é efectuada com o intuito de manter a maior linearidade possível aquando a atribuição das classes de treino para cada ensaio de classificação.




Figura 11 - Nomenclatura proposta por Níveis de Reconhecimento



Classes Nível 4	Amostra Visual	Cor em Falsa cor 3/5/7	Forma e Tamanho	Textura
Edifícios com cobertura cerâmica	 	Várias tonalidades de Verde	Variável	Variável
Edifícios com cobertura de betão	 	Várias cores de cinzento	Variável	Variável, indo do pouco a muito texturizada.
Edifícios com cobertura Metálica	 	Branco brilhantes, com alguma tonalidade cinzenta	Variável.	Variável, indo do pouco a muito texturizada.

Tabela 3 – Chave de Identificação das Classes de nível 4, agrupadas em 3, por ‘Edifícios’


Classes Nível 4	Amostra Visual	Cor em Falsa cor 3/5/7	Forma e Tamanho	Textura
Pistas, Campos de ténis, Ciclovias		Verde	Variável, dependendo dos elementos que agrupa, vai desde de linear, a oval a rectangular.	Suave
Relvados Sintéticos e Campos de Jogos com pavimento de betão	 	Preto	Rectangular e tamanho variável.	Suave, muito homogénea

Tabela 4 – Chave de Identificação das Classes de nível 4, agrupadas em 3, por ‘Infra-Estruturas Desportivas’


Classes Nível 4	Amostra Visual	Cor em Falsa cor 3/5/7	Forma e Tamanho	Textura
Pavimento Betuminoso		Várias tonalidades de Cinzento	Variável	Textura suave quando se encontra sem carros, e com muita textura quando se trata de um parque de estacionamento
Passeios e áreas Pedonais		Creme	Variável	Moderada

Tabela 5 – Chave de identificação das classes de nível 4, agrupadas em 2, por ‘Eixos de Circulação’

Classes Nível 4	Amostra Visual	Cor em Falsa cor 3/5/7	Forma e Tamanho	Textura
Vegetação Resinosa		Vermelho escuro, com alguns pixéis muito escuros.	Arredondada	Muito texturada
Vegetação Folhosa		Vermelho vive a escuro, dependendo da espécie e da idade da árvore.	Arredondada	Muito texturada
Vegetação Herbácea		Diferentes tonalidades de vermelho, mas geralmente mais vivo		Suave, mas com alguma textura quando intervalada por a classe 'Solo Exposto'

Tabela 6 – Chave de identificação das classes de nível 4, agrupadas em 2, por 'Vegetação'



Classes	Amostra Visual	Cor em Falsa cor 3/5/7	Forma e Tamanho	Textura
Nível 4				
Solo Exposto		Castanho e por vezes com cor acinzentada quando se trata de solo exposto muito empobrecido	Variável	Variável
Água		Preta	Variável	Suave
Sombra		Preta	Variável, dependendo do objecto que a projecta	Suave

Tabela 7 – Chave de identificação das classes de nível 4, agrupadas em 2, por ‘Não Vegetação’

Determinado o esquema de classificação dá-se início aos ensaios de classificação da imagem propostos.

A selecção das áreas de treino irá ser, dentro do possível, mantida para os diferentes tipos de abordagem, tanto em número, bem como a distribuição espacial das mesmas. Uma grelha de doze quadrantes divide a imagem em rectângulos iguais, com uma área aproximada de 50 ha cada um, servindo de guia na distribuição das áreas de treino, de forma a manter uniforme a sua atribuição. Uma área de treino é seleccionada por cada classe e por cada quadrante, sempre que possível, sempre que esta exista. No caso da classe água, a eleição das áreas de treino foi alterada por esta existir em apenas em dois quadrantes, tal como foi também reduzida a sua dimensão a menos de metade.

No caso da abordagem por objectos o procedimento adoptado foi diferente, pois por cada nível da nomenclatura é realizada uma nova classificação, até estarem representadas as treze classes propostas da nomenclatura. A distribuição espacial é comum aos procedimentos anteriores, contudo a atribuição das classes segue outra regra, embora se tente que seja o mais semelhante possível aos anteriores. Este processo irá ser descrito aquando a metodologia for apresentada.

III.2.2. Ensaios de Classificação *WORLDVIEW-2*

III.2.2.1. Classificação *Pixel a Pixel*

A classificação supervisionada, *pixel a pixel*, por forma a testar e aprovar as classes seleccionadas. Para tal, irá se usar novamente o *software* ENVI em combinação com o *R*. O algoritmo usado nesta classificação será o *random forests*.

O processo tem início com a selecção das áreas de treino para cada classe, o total das mesmas foi 144, perfazendo uma área de 2.304 m². A sua distribuição pode-se observar na tabela 8.

Classe	Nº Áreas de Treino	Área Total Amostrada (m ²)
Edifícios com cobertura cerâmica	12	192
Edifícios com cobertura de betão	12	192
Edifícios com cobertura Metálica	12	192
Pistas, Campos de Ténis, Ciclovias	8	128
Relvados Sintéticos e Campos de Jogos com pavimento de betão	10	160
Pavimentos betuminosos	12	192
Passeios e outras áreas pedonais	12	192
Vegetação Arbórea Resinosa	12	192
Vegetação Arbórea Folhosa	12	192
Vegetação Herbácea	12	192
Solo Exposto	12	192
Água	6	96
Sombra	12	192

Tabela 8 – Distribuição das áreas de treino por classe de nível 4

Em seguida, extraiu-se os valores dos atributos das áreas de treino, em formato ASCII, para que se possa realizar uma análise estatística sobre os mesmos no *software R* (Figura 12).




Figura 12 – Fluxograma do processo de atribuição e exportação das áreas de treino

Realizada a exportação das variáveis, dá-se início ao tratamento dos dados exportados no *R*. Em primeiro, corre-se o seguinte código, registado num *script*, no qual se vai determinar a melhor combinação das variáveis. O conteúdo do *script* vem comentado e explicado na figura que se segue (Figura 13).

```

## Faz-se o upload do conteúdo do algoritmo random forests
library(randomForest)

## Define-se a directoria de trabalho
setwd('D:/...')

## Define-se o número de variáveis a testar
mt <- c(1, 2, 3, 4, 5, 6, 7, 8,9,10,11,12,13)

## Define-se o número de “árvores” a testar
nt <- c(100, 200, 300, 400, 500, 700, 900, 1000, 2000, 3000, 4000, 5000)

## Ler a tabela com os valores das Áreas de treino, sua localização geográfica e valor das
bandas.

model.data <- read.table("CasoEstudo_13CL.csv",
                        header=TRUE,
                        sep=";",
                        dec=".")
  
```

Figura 13 – Script R comentado, onde se determinada a melhor combinação das variáveis

```

## Conversão do número de cada classe a um factor
model.data$CLASS_NUMBER<-factor(model.data$CLASS_NUMBER)

## Define-se o valor de início para incrementar no comando set.seed
a<-0

## Para cada ciclo testa-se as várias combinações do mtry & ntree, devolvendo um output
com uma tabela para posterior análise.

for (i in 1:13) {
  for (j in 1:12) {
    b<-1968+a
    set.seed(b)
    class <- randomForest(CLASS_NUMBER ~ B1 + B2 + B3 + B4 + B5 + B6 + B7 + B8,
                          data=model.data, ntree=nt[j], mtry=mt[i], replace=TRUE,
                          importance=TRUE, keep.forest=FALSE)
    output <- t(c(class$mtry, class$ntree, class$serr.rate[nt[j]], b))
    write.table(output, "CasoEstudo_8CL_RF_LOOP.csv", append=TRUE)
    rm(class)
    a<-a+1 } }

```

Figura 13 – Script R comentado, onde se determinada a melhor combinação das variáveis (continuação).

Após esta análise estatística, que nos conduz à melhor combinação das variáveis, inicia-se a segunda operação no *R* que nos devolve a proporção de ‘votos’ destinados a cada classe, e a atribuição das classes, tendo por base o modelo estatístico *random forests* (Figura 14).

```

## Faz-se o upload do conteúdo do random forests

library(randomForest)

## Define-se a directoria de trabalho

setwd('D:/...')

```

Figura 14 – Script R comentado, onde são atribuídas as classes da imagem e a proporção de votos para cada uma

```

## Ler a tabela com os valores das Áreas de treino, sua localização geográfica e valor das
bandas.
model.data <- read.table("CasoEstudo_13CL.csv",
                        header=TRUE,
                        sep=";",
                        dec=".")

## Conversão do número de cada classe a um factor
model.data$CLASS_NUMBER<-factor(model.data$CLASS_NUMBER)

## O valor de seed correspondente à melhor combinação das variáveis.
set.seed(1972)

## Aplicação do Random Forest com a combinação otimizada dos parâmetros mtry &
ntree
class <- randomForest(CLASS_NUMBER ~ B1+ B2 + B3 + B4 + B5 + B6 + B7 + B8,
                      data=model.data,
                      ntree=500,
                      mtry=1,
                      replace=TRUE,
                      importance=TRUE)

## Registo da taxa de erro, matriz de confusão e relevância
print(class$err.rate)
print(class$confusion)
print(class$importance)

## Leitura de uma tabela com os valores das 8 bandas da Imagem referente ao Estudo de
Caso
image<-read.table("CasoEstudo_B12345678_Tshld.txt",
                 header=TRUE,
                 dec=".")

## Previsão para cada classe na imagem.
class.response<-predict(object=class,
                       newdata=image,
                       type="response")

```

Figura 14 – Script R comentado, onde são atribuídas as classes da imagem e a proporção de votos para cada uma (continuação)

```

## Cálculo da proporção de votos para cada classe
class.vote<-predict(object=class,
                    newdata=image,
                    norm.votes=TRUE,
                    type="vote")

## Registo da Previsão para cada classe num ficheiro CSV (comma separated values)
write.table(class.response,
            "CasoEstudo_13CL_RFresponse.csv",
            quote=FALSE,
            sep=",")

# Registo da Proporção de votos para cada classe num ficheiro CSV
write.table(class.vote,
            "CasoEstudo_13CL_RFvote.csv",
            quote=FALSE,
            sep=",")

```

Figura 14 – Script R comentado, onde são atribuídas as classes da imagem e a proporção de votos para cada uma (continuação)

Terminado o processamento no R e classificado cada pixel da imagem, corre-se um programa em linguagem IDL, no *ENVI*, que traduz os resultados obtidos no modelo estatístico numa Imagem classificada (Figura 15).

```

-- Definir o número de linhas e colunas, dos ficheiros resultantes do tratamento
estatístico, que correspondem ao número pixels de toda a imagem.

response = ulonarr(2,1501668,/nozero)

vote    = fltarr(9,1501668,/nozero)

order = 0ul

-- Definir o número de linhas e colunas, dos ficheiros resultantes do tratamento
estatístico, que correspondem ao número pixels de toda a imagem.

response = ulonarr(2,1501668,/nozero)

vote    = fltarr(9,1501668,/nozero)

-- Processar os ficheiros de texto com os valores de classificação para cada pixel e a
exactidão associada; e registar.

GET_LUN, u

openr, u, $
'D:\...\ EstudoCaso_13CL_RFresponse.csv'

readf, u, response

close, u

FREE_LUN, u

;

GET_LUN, u

openr, u, $
'D:\...\ EstudoCaso_13CL_RFvote.csv'

readf, u, vote

close, u

FREE_LUN, u

;

```

Figura 15 – Script usado no IDL+ENVI de onde resulta a Imagem Classificada.

```

-- Output da Imagem com a classificação e os valores de exactidão.

pix_per_line    = 1414
num_lines       = 1062
num_layers      = 1
output_response = bytarr(pix_per_line, num_lines, num_layers)
output_vote     = fltarr(pix_per_line, num_lines, num_layers)
order           = 0ul

-- For loop to calculate the response and corresponding accuracy value
for j=0, (num_lines-1) do begin
  for i=0, (pix_per_line-1) do begin
    output_response(i,j,0) = response(1,order)
    output_vote(i,j,0) = max(vote(1:13,order))
    order = order+1
  endfor
endfor

get_lun, u
openw, u, $
'D:\...\ EstudoCaso_13CL_RFresponse.env'
writu, u, output_response
close, u
free_lun, u
get_lun, u
openw, u, $
'D:\...\ EstudoCaso_13CL_RFvote.env'
writu, u, output_vote
close, u
free_lun, u
end

```

**Figura 15 – Script usado no IDL+ENVI de onde resulta a Imagem Classificada
(continuação)**

Executados os scripts que classificam o estudo de caso, pode-se agora abrir a imagem no ENVI e proceder a reclassificação da imagem, identificando cada classe do resultado obtido do processamento. Através do comando *Edit Header* no ENVI (figura 16).




Figura 16 – Fluxograma do Processamento final no ENVI, identificação de cada classe.

III.2.2.2. Classificação Orientada por Segmentos

Após a classificação supervisionada *pixel a pixel* do estudo de caso presente, existe um maior conhecimento sobre as características da imagem em questão. Em seguida, damos início ao processo de segmentação de imagem no *IDRISI Taiga*, e posterior classificação *orientada por objectos*.

O software *IDRISI Taiga* possibilita a segmentação e classificação de objectos e vários são os parâmetros que se podem manipular. Este processo tem três fases, a primeira trata-se da segmentar a imagem em objectos semelhantes, que tenham idêntico comportamento espectral (figura 17). Os parâmetros a manipular são: a proporção de cada banda do espectro, a tolerância de similaridade permitida entre objectos, tamanho da janela de varrimento (*Window Width*) que examina a imagem, e os factores de média e variância.




Figura 17 – Fluxograma do Processamento de Segmentação da Imagem

Os parâmetros vão ser manipulados e ensaiados segundo esta ordem (mantendo todos os outros valores, por aferir, os sugeridos por defeito pelo *software*):

1º. **Valor para a tolerância de similaridade entre segmentos**, pode ir de 1 a 100, sendo o 1 muito pouco tolerante e o 100 o oposto. Os valores testados são o 50, o 30 e o 10.

2º. **Tamanho da janela de varrimento** que examina a imagem, de 2x2, 3x3 e 4x4.

3º. **Valores de média (weight mean factor, WMF) e variância (weight variance factor, WVF)**, cuja soma é igual a um.

4º. Diferentes importâncias para **as bandas electromagnéticas**.

Após o processo de Segmentação da Imagem dá-se início à atribuição das áreas de treino (figura 18); estas são dadas seleccionando polígonos resultantes da imagem e atribuindo-lhes uma das classes.




Figura 18 – Atribuição das áreas de treino sobre a imagem segmentada

Neste processo usou-se a mesma grelha anteriormente aplicada, para que servisse de guia à atribuição das classes de treino, para que ficassem uniformemente distribuídas pela imagem. A regra seguida foi dar 1 área de treino a cada classe por cada rectângulo, sempre que fosse possível, e sem adjacência entre si. O número total de áreas de treino dadas foi na ordem das 139 com uma área total aproximada de 30 km². A sua distribuição pode-se observar na tabela 9.

Classe	Nº Áreas de Treino	Área Total Amostrada (m ²)
Edifícios com cobertura cerâmica	12	1.960
Edifícios com cobertura de betão	12	3.460
Edifícios com cobertura Metálica	12	2.524
Pistas, Campos de Ténis, Ciclovias	5	1.152
Relvados Sintéticos e Campos de Jogos com pavimento de betão	11	3.276
Pavimentos betuminosos	12	4.128
Passeios e outras áreas pedonais	12	2.060
Vegetação Arbórea Resinosa	12	1.972
Vegetação Arbórea Folhosa	12	1.528
Vegetação Herbácea	12	2.572
Solo Exposto	12	2.036
Água	3	1.316
Sombra	12	2.408

Tabela 9 – Distribuição das áreas de treino por classe de nível 4

Terminadas as tarefas de segmentação da imagem, e atribuição das áreas de treino, procede-se a uma classificação *pixel a pixel* da imagem com o classificador *nearest neighbor*. Procedimento intermédio obrigatório para a última operação de classificação da imagem por segmento, no *IDRISI Taiga*.




Figura 19 – Fluxograma do processamento de classificação da imagem com o classificador *nearest neighbor* pelas áreas de treino definidas no *IDRISI Taiga*

A última etapa de classificação da imagem por segmentos no *IDRISI Taiga*, o módulo *SEGCLASS*, é agora processada com a imagem resultante da classificação *pixel a pixel*, com o algoritmo *nearest neighbor* e o ficheiro vectorial resultante da melhor segmentação da imagem (figura 20).




Figura 20 – Fluxograma do processamento da aplicação do algoritmo de maioriação *SEGCLASS*

III.2.2.3. Classificação Combinada, *Pixel a Pixel* agrupada *por Segmentos*

Realizadas as duas primeiras abordagens, *pixel a pixel* e a *orientada por segmentos*, é possível executar uma classificação que combina o resultado da primeira com os segmentos criados aquando o processamento da imagem no *IDRISI Taiga*.

Em suma, o que se irá realizar neste ensaio é uma reorganização da classificação *pixel a pixel* pelos segmentos criados no ensaio 2.

A única tarefa consiste em classificar a imagem originada no ensaio 1 por segmentos no *IDRISI Taiga*, com o módulo SEGCLASS. Como se observa na figura 21.




Figura 21 – Fluxograma do processamento da classificação da imagem *pixel a pixel* por Segmentos

III.2.2.4. Classificação *Orientada por Objectos*

O processamento de imagem do *eCognition 8.0* inicia-se, à semelhança de *IDRISI Taiga*, pela segmentação da imagem em objectos análogos. Contudo, não tem apenas em consideração dados radiométricos, entra em conta com outras características, são estas a forma, a textura e a topologia.

Os algoritmos de segmentação, do *eCognition 8.0*, dividem a imagem ao nível do píxel ou com uma forma específica do nosso interesse. No presente estudo irá se escolher a primeira opção, pois o objectivo é segmentar a imagem por igual, sem realce de nenhum objecto em particular, de forma a ser possível fazer uma análise equiparada mais linear entre os diferentes ensaios de segmentação.

O algoritmo eleito para fazer a segmentação da imagem nesta abordagem é o *multiresolution*, pois este permite que os objectos sejam identificados independentemente do seu tamanho, bem como ser possível a associação entre si em diferentes escalas de representatividade. Ou seja, são alocados a diferentes classes, consuante o nível hierarquico.

Os parâmetros a manipular, na fase de segmentação da imagem, são a *scale*, nível de tolerância para a heterogeneidade dos objectos, e a relevância a dar às variáveis Cor e Textura, onde se optou por atribuir igual valor a ambas. Contudo assume-se que a manipulação destas variáveis poderia ser útil se fosse realizado outro tipo de processamento mais minucioso, contudo bem mais moroso.

A *scale*, vai ser o único princípio a ser manuseado aquando a segmentação da imagem, este também determina qual a tolerância de similariedade entre objectos.




Figura 22 – Fluxograma do processamento de segmentação da imagem

Segmentada a imagem, inicia-se o processo de classificação por níveis, pelo classificador *nearest neighbor*. Neste processamento, a classificação é feita classe a classe, partindo inicialmente do nível 1 e seguindo a mesma lógica pela qual as classes estão agrupadas e se vão dividindo na nomenclatura proposta.

A primeira classificação recai em separar as classes de nível 1, o 'Urbano' da 'Não Urbano', pelo algoritmo *nearest neighbor*. Para tal são atribuídas, segundo a mesma grelha de dispersão, as áreas de treino, uma por cada classe de nível 4 que a categoria em processamento agrupa. Ou seja, para qualificar a Super-Classe 'Urbano' vamos ter, por cada quadrante, 7 áreas de treino representativas das subclasses categorizadas no nível 4, bem como 6 áreas de treino para identificar a Super-Classe 'Não Urbano'.

A segunda classificação recai sobre reclassificar os objectos identificados pela Super-Classe 'Urbano', separando agora as duas classes de nível 2, os 'Edifícios e as Infra-estruturas Desportivas' dos 'Eixos de circulação', dando 5 áreas de treino à primeira e 2 áreas de treino à segunda, por cada quadrante. O raciocínio vai ser este até ao fim da classificação da imagem.

Um fluxograma sobre o processamento da imagem no *eCognition 8.0*, sua segmentação e classificação, é apresentado na figura 23. A classificação é feita por camadas, sucessivamente, até termos todos os objectos distribuídos pelas classes que determinamos.




Figura 23 – Fluxograma do processamento de classificação da imagem por níveis

Este processo é repetido, pela mesma ordem e com as mesmas áreas de treino, para as duas opções de identificação espacial do objecto (IEO), são estas: Cor e Textura (CT), e Cor e Contexto (CC). O número de áreas de treino e a área amostrada por cada classe está registado na tabela 10.

Classes		Nº Áreas de Treino	Área Total Amostrada (m ²)
Nível 1	Urbano	69	39.708
	Não Urbano	64	42.724
Nível 2	Edifícios e Equipamentos Desportivos	10	6.352
	Eixos de Circulação	24	13.408
	Vegetação	36	19.860
	Não Vegetação	25	13.060
Nível 3	Edifícios	36	9.428
	Equipamentos Desportivos	34	14.780
	Vegetação Arbórea	24	8.104
	Vegetação Herbácea	12	7.848
Nível 4	Edifícios com cobertura cerâmica	24	3.524
	Edifícios com cobertura de betão	12	5.576
	Edifícios com cobertura metálica	12	4.068
	Pistas, Campos de Ténis, Ciclovias	5	2.528
	Relvados Sintéticos e Campos de Jogos com pavimento de betão	5	3.328
	Pavimentos betuminosos	12	9.368
	Passeios e outras áreas pedonais	12	3.604
	Vegetação Arbórea Resinosa	12	3.200
	Vegetação Arbórea Folhosa	12	4.844
	Vegetação Herbácea	12	7.848
	Solo Exposto	12	7.540
	Água	3	2.396
	Sombra	12	6.548

Tabela 10 – Distribuição das áreas de treino por classe de nível 4

III.2.3. Análise de Exactidão

O processo de análise de exactidão tem início no lançamento aleatório de 50 pontos sobre cada uma das classes categorizadas, resultantes de cada uma das classificações *orientadas por segmentos* e *por objectos* (em formato vectorial), ver figura 24. O lançamento de pontos foi também executado sobre a classificação *pixel a pixel*, contudo esta não se mostrou representativa para a comparação da análise de exactidão para as classificações anteriormente referidas, que dão argumento à presente tese. A ferramenta que auxiliou o lançamento aleatório dos pontos, é uma extensão do *arcGis 10.0*, *Hawths Tools*.




Figura 24 – Fluxograma relativo ao lançamento aleatório de pontos por classe

Realizada a amostragem de pontos, observou-se para cada ponto qual a classe a que este deveria pertencer. Usando como informação de referência o *subset* da imagem *WorldView-2* do estudo de caso e como informação complementar os sistemas de informação disponibilizados no *google earth* e no *bing*.

Terminado este processo aferiu-se, através da intersecção das classificações com os pontos observados, os valores que iriam preencher a matriz de confusão, ou seja, os valores das unidades observados e os valores classificados (figura 25).




Figura 25 – Fluxograma relativo à intersecção das unidades identificadas sobre as classificações

Realizado o processo de apuramento das unidades de referência é levado a cabo o estudo de avaliação da análise de exactidão, através das matrizes de confusão, bem como a aferição do Índice de Concordância Kappa.

CAPÍTULO IV. ANÁLISE DOS RESULTADOS

Neste capítulo apresenta-se a classificação resultante de cada processo adoptado e, em alguns casos, resultados intermédios, como por exemplo a segmentação de imagem obtida pelos diferentes softwares (*IDRISI Taiga* e *eCognition 8.0*).

IV.1. Classificação *Pixel a Pixel*

A classificação supervisionada da imagem, do caso de estudo, pela abordagem *pixel a pixel*, pelo modelo estatístico *random forests*, apresenta-se na figura 26.




Figura 26 - Resultado da classificação *pixel a pixel*, pelo algoritmo *random forests*

IV.2. Classificação *Orientada por Segmentos*

A classificação *orientada por segmentos*, tem início na segmentação da imagem, do caso de estudo, no software *IDRISI Taiga*, entre os parâmetros ensaiados, optou-se por realizar a classificação sobre a segmentação obtida por uma janela de varrimento 2x2, WMF igual a 0.75 e WVF igual a 0.25, com um valor de tolerância entre segmentos de 1%. Na figura 27, podemos observar uma amostra da imagem segmentada por 51.149 polígonos, com os parâmetros anteriormente descritos.




Figura 27 – Amostra da imagem segmentada no *IDRISI Taiga*

A figura 28 é referente ao resultado intermédio da classificação *orientada por segmentos*, apresenta o resultado da classificação, ainda ao nível do pixel, pelo algoritmo *nearest neighbor*, com as áreas de treino atribuídas sobre os segmentos.




Figura 28 - Resultado intermédio da classificação *orientada por segmentos*, pelo algoritmo *nearest neighbor*

A figura 29 corresponde ao resultado final obtido pela classificação *orientada por segmentos*, pelo algoritmo *nearest neighbor*.




Figura 29 - Resultado final da classificação *orientada por segmentos*, pelo algoritmo *nearest neighbor*

IV.3. Classificação Combinada, *Pixel a Pixel* agrupada por Segmentos

A classificação combinada aplica o algoritmo de majoração da classificação *orientada por segmentos* sobre a classificação obtida no ponto 1, *pixel a pixel*, onde as áreas de treino são distribuídas ao nível do pixel. Os segmentos apenas os irão agrupar, dando o valor da classe cujos pixels são mais frequentes dentro do segmento. O resultado desta classificação do Caso de Estudo é apresentado na Figura 30.




Figura 30 - Resultado final da classificação combinada, *pixel a pixel* agrupada por segmentos

IV.4. Classificação *Orientada por Objectos*

Na figura 31, podemos observar uma amostra resultante da segmentação da imagem pelo software *eCognition 8.0*, pelo algoritmo *multiresolution*, em 50.586 polígonos, com igual relevância para o valor de cor e textura.




Figura 31 – Amostra da imagem segmentada pelo algoritmo *multiresolution*

A classificação *orientada por objectos*, exectuda pelo *eCognition 8.0*, pelo algoritmo *nearest neighbor*, permite 3 opções de identificação espacial do objecto, pela 'Cor' apenas, depois combina este factor com a 'Textura' ou com o 'Contexto' do pixel, optou-se pelas duas últimas classificações do caso de estudo que se apresentam na figura 32 e 33.




Figura 32 - Resultado final da classificação *orientada por objectos*, *eCognition 8.0*, pela cor e textura (CT)




Figura 33 - Resultado final da Classificação *Orientada por Objectos*, eCognition 8.0, pela *Cor e Contexto (CC)*

O número de objectos alocados por classe é visível na tabela 11, para que se possa ter uma noção mais exacta sobre as diferenças entre as diferentes classificações.

Classe	CT	CC
Edifícios com cobertura cerâmica	6.574	5.112
Edifícios com cobertura de betão	12.029	9.311
Edifícios com cobertura Metálica	4.390	4.048
Pistas, Campos de Ténis, Ciclovias	296	1.050
Relvados Sintéticos e Campos de Jogos com pavimento de betão	288	1.301
Pavimentos betuminosos	2340	2.629
Passeios e outras áreas pedonais	12.338	14.657
Vegetação Arbórea Resinosa	3.537	2.923
Vegetação Arbórea Folhosa	1.482	1.652
Vegetação Herbácea	2.035	1.010
Solo Exposto	2.621	3.602
Água	13	21
Sombra	2.626	3.258

Tabela 11 – Objectos Classificados por classe e por critério de identificação espacial

CAPÍTULO V. Discussão dos Resultados

A dimensão dos dados característicos das imagens de alta resolução espectral e espacial torna o processo de classificação da imagem trabalhoso e complexo. As diferentes abordagens de classificação revelam a dificuldade de categorizar os elementos urbanos sobre este tipo de imagens, apesar do nível de detalhe que as caracteriza. A heterogeneidade espectral e a multiplicidade de formas que os elementos urbanos assumem indicam o quão ambicioso se trata a classificação de dados relativos a áreas urbanas.

O processamento deste tipo de imagens obriga a um bom conhecimento por parte do operador da área urbana sobre o qual recai o estudo, para que a selecção das áreas de treino seja representativa para cada classe. O classificador por si só já terá dificuldades em separar as classes que se assemelham em sua assinatura espectral, ou na sua forma. A segmentação correcta da imagem é essencial para que se possa seleccionar as áreas de treino, com a menor contaminação possível dos elementos urbanos vizinhos, para que não haja constrangimentos aquando a classificação das imagens.

A discussão está organizada em três subcapítulos, no primeiro faz-se uma análise comparada sobre os resultados da segmentação da imagem pelos diferentes algoritmos, disponibilizados pelo *softwares IDRISI Taiga* e *eCognition 8.0*. Numa segunda fase procede-se à avaliação de exactidão, onde se realiza uma análise sobre a exactidão global e o Índice de Concordância Kappa para as distintas classificações obtidas pelas diferentes abordagens. Por fim, faz-se uma análise geral dos resultados e propõe-se outro tipo de abordagens para a classificação deste tipo de imagem para estudos futuros.

V. 1. Análise Comparada dos Processos de Segmentação

A segmentação ensaiada nos *softwares IDRISI Taiga* e *eCognition 8.0*, revelaram-se muito dissemelhantes. O tipo de parâmetros a manipular, em cada um, é distinto; no primeiro, estes são de origem radiométrica, já no segundo estão mais interligados à forma, à assinatura espectral e contextual dos elementos urbanos. O

resultado de individualização dos diferentes elementos urbanos, que constituem a imagem, por ambos os *softwares* revela-se bastante distinto.

Em seguida, encontra-se uma explanação sobre os ensaios experimentados, dificuldades encontradas, discussão dos resultados intermédios e o porquê da selecção de determinada combinação de variáveis que elegem a segmentação pela qual foi efectuada a classificação final. Depois de comentados os resultados dos algoritmos em separado, fez-se uma análise comparada dos mesmos.

No *IDRISI Taiga* foram ensaiados e combinados os diversos parâmetros radiométricos disponibilizados pelo módulo de segmentação de imagem. O primeiro parâmetro experimentado foi o nível de tolerância de similaridade (*scale*) permitida entre segmentos (representativos dos elementos urbanos); enquanto se fixou os valores que o *software* dá por defeito para os outros parâmetros. O valor que o parâmetro *scale* assume tem extrema relevância na segmentação da imagem; verificou-se que à medida que se diminui o seu valor, o número de segmentos que divide a imagem aumenta exponencialmente. Para um valor de 50, o algoritmo segmentou a imagem em 194 polígonos, e para um valor de 10, este individualiza um total de 9.525 segmentos (tabela 12). No entanto, este parâmetro por si só não é suficiente para a correcta individualização dos elementos urbanos, o aumento do número de segmentos embora seja significativo na distinção dos mesmos não compreende um nível aceitável para a selecção das áreas de treino. O delineamento pôde ser melhorado através da manipulação dos outros parâmetros, que até ao momento tinham sido considerados os que o *software* apresentava por defeito. Na tabela 12, está um registo dos resultados intermédios obtidos nestes ensaios, que serve para a presente discussão.

Os valores dos parâmetros eleitos para os ensaios foram escolhidos e justificados pelas características da imagem. Nomeadamente, a janela de varrimento inicialmente dada pelo *software* com um valor de 3, foi primeiro aceite e depois alterada de acordo com o tamanho do pixel, primeiro com o dobro de sua dimensão, a que corresponde o valor 4 e depois pela medida do pixel, ou seja, 2. Os valores para a média e desvio padrão foram também experimentados em sua proporção, optando-se por dar maior relevância à similitude entre *pixels*. Por fim, foi ensaiado o processo de

segmentação alterando a proporção das bandas do espectro electromagnético, que até ao momento tinha sido igual. Optou-se, depois de analisado o histograma, por uma proporção que deixava de ser igual e passava a ser distribuída em 75% às bandas 3, 5 e 7, e os restantes 25%, repartidos igualmente, pelas outras 5 bandas; onde se verificou um ganho de 500 segmentos. O que demonstra que a proporção com que as bandas são lidas tem efeitos no resultado do processamento, contribuindo para uma melhoria, ou não, na individualização dos elementos urbanos.

	Proporção		Tolerância de Similaridade entre objectos	Tamanho da Janela de Varrimento da Imagem	Weight Mean Factor (WMF)	Weight Variance Factor (WVF)	Número de Objectos
Bandas Igualmente Distribuídas	B1	1.25	50	4	0.5	0.5	183
	B2	1.25		3			194
	B3	1.25		2			176
	B4	1.25	30	4	0.5	0.5	890
	B5	1.25		3			925
	B6	1.25		2			912
	B7	1.25	10	4	0.5	0.5	9.525
	B8	1.25		3			10.155
	B9	1.25		2			10.277
Bandas Desigualmente Distribuídas	B1	0.08	10	4	0.5	0.5	9792
	B2	0.08		3			10.382
	B3	2.5		2			10.464
	B4	0.08	10	2	0.75	0.25	11.839
	B5	2.5			0.25	0.75	8.629
	B6	0.08					
	B7	2.5					
	B8	0.08					
	B9	0.08					

Tabela 12 – Parâmetros manipulados no processamento de segmentação no IDRISI

Taiga

A contabilização dos segmentos foi feita para cada ensaio, contudo a escolha dos valores para cada parâmetro teve também fundamento na análise visual dos resultados. Na figura 34, uma amostra visual do processo de individualização dos segmentos.





Figura 34 – Amostra visual do processo de individualização dos segmentos

Os resultados revelam embaraço na individualização dos elementos urbanos, no primeiro exemplo verifica-se que a vegetação presente é erradamente delineada, ficando incluída em outras classes, como no solo exposto e no pavimento. Na manipulação seguinte, a vegetação já se encontra mais individualizada, contudo, continua a estar no interior de outros segmentos. No terceiro resultado discutido, a

vegetação consegue servir de razão para o corte de alguns segmentos, no entanto mantém o mesmo nível de individualização, observando-se a maior dificuldade de quando se apresenta em menor dimensão e com uma forma mais linear.

Outro ponto a salientar é que o acréscimo de segmentos que ocorreu do primeiro para o segundo exemplo, revela que o ganho em número de segmentos recai mais sobre elementos já anteriormente identificados correctamente, dividindo-os por um ou mais polígonos, do que na individualização de novos elementos. Para se averiguar esta questão, sobrepôs-se a segmentação obtida pelo segundo e terceiro exemplo, ou seja, a combinação de parâmetros com janela de 2x2, e WMF=0.75 & WVF=0.25, variando a apenas a distribuição das bandas do espectro electromagnético. Nesta segunda amostragem visual da imagem, figura 35, a linha branca corresponde aos segmentos individualizados para igual distribuição das bandas, e a amarelo o acréscimo de segmentos individualizados quando se valoriza a leitura das bandas 3, 5 e 7.



1:2.000 ▲

Figura 35 – Amostra visual da sobreposição de dois resultados de segmentação

Observa-se que o segundo permite a individualização de algumas sombras, neste caso, bem como a separação de um 'Edifícios com cobertura cerâmica' da 'Vegetação', mas que não traz grandes avanços na mitigação da contaminação de uns segmentos para outros.

O ganho em termos de número de segmentos, aquando a manipulação dos parâmetros, é grande, contudo este não tem relação directa com o nível de individualização dos elementos urbanos.

A consequência destes resultados obriga que o algoritmo de segmentação seja levado quase ao extremo da sua aplicação, optando-se por dar um nível de tolerância 1 entre segmentos (e a combinação Janela 2x2, WMF=0.75 & WVF=0.25, e bandas desigualmente distribuídas), por forma a individualizar ao máximo os segmentos, para que as áreas de treino sejam atribuídas com maior rigor, sem o “ruído” dos *pixels* dos segmentos vizinhos.

Na segmentação da imagem pelo *eCognition 8.0*, o factor *scale* foi ensaiado, para o algoritmo *multiresolution*, para que o número de polígonos fosse algo semelhante ao obtido no *IDRISI Taiga*. Aquando este procedimento foi observado que para um factor de *scale* 30, maior parte dos objectos, num total de 11.282, era identificável. Contudo, não se verificava ainda a precisão ambicionada para o contorno de todas as unidades da imagem. Vários ensaios se seguiram, até ser alcançado o valor *scale* 15, onde se obtém 50.586 objectos (valor equiparado em número ao obtido pelo *IDRISI Taiga*). O nível de pormenor devolvido por este ensaio revela um delineamento mais preciso dos objectos, no entanto consequência a extracção de elementos urbanos tão pequenos, como os carros, que irão por sua vez gerar ruído na classificação, visto não estarem atribuídos a nenhuma classe em específico. Na figura 36, compara-se uma amostra visual do primeiro resultado e do final com o qual se irá seguir para a classificação.




Figura 36 – Amostra visual do processo de individualização dos objectos

Verificou-se que o primeiro resultado da individualização dos objectos é relativamente bem-sucedido, em maior parte dos mesmos, embora se veja erros grosseiros, neste caso observa-se uma sombra que se encontra no mesmo polígono de vegetação. Na mesma amostra, com o factor *scale* de 15 verifica-se um maior rigor de delineamento dos objectos, porém alguns já anteriormente bem delimitados assumem aqui a sua partição múltipla.

Em seguida, procedeu-se a uma comparação mais directa sobre os dois algoritmos de segmentação, resultantes dos diferentes *softwares*, que foram usados aquando a classificação das imagens, em áreas com características distintas. Primeiro sobre uma área mais ampla e menos texturizada (figura 37), e a segunda recai sobre uma área de maior densidade urbanística alternada com vegetação arbórea (figura 38).




Figura 37 – Primeira amostra visual dos algoritmos de segmentação de cada *software* experimentado




Figura 38 – Segunda amostra visual dos algoritmos de segmentação de cada *software* experimentado

Várias são as diferenças encontradas e que se observam nos resultados de segmentação entre um e outro *software*. Nomeadamente:

1. O ***rigor de delineamento***, observado em (2) em oposição a (1) que apresenta vários segmentos tingidos por segmentos adjacentes. Em (2) no limiar dos objectos, é muitas vezes separada uma linha de pixels que fazem parte da bordadura dos mesmos. O mesmo não se passa em (1) em que estes pixels de transição e de classificação algo dúbia, caem dentro de um ou outro segmento. A individualização exemplar dos segmentos e dos objectos é essencial aquando a fase de atribuição das áreas de treino. O resultado de (1), advinha embaraço na fase de treinamento, o que de facto se comprovou.
2. A ***identificação de todas unidades da imagem***, em (1) quase todos os elementos se encontram diferenciados, no entanto continuam-se a observar casos em que tal não acontece, como o caso da classe vias muitas vezes miscegenado com a classe de vegetação e outras. O mesmo ocorre com frequência em pequenas porções de vegetação herbácea que não são individualizadas em (1).
3. A ***sobre-fragmentação*** dos segmentos e dos objectos, acontece em ambos os resultados, factor mais compreensível quando se trata de elementos muito texturizados, porém ocorre também em texturas mais suavizadas como por exemplo se observa na porção de vegetação herbácea contínua presente nesta amostra. Este factor parece ocorrer mais em (1), do que em (2), veja-se para o mesmo exemplo que a vegetação herbácea em (1) está dividida por quase 30 segmentos e em (2) por menos de metade dos primeiros. A excessiva partição das unidades da imagem causa alguma entropia aquando a classificação da imagem, pois esta é realizada pelo algoritmo nearest neighbor.
4. O ***nível de pormenor***, é deveras importante na individualização de objectos de menor dimensão. Porém, a partir de determinado grau de minuciosidade, poderá incorrer no delineamento de objectos que não têm interesse na sua individualidade, como os carros, que não têm uma classe especificada, estando inclusos na classe 'Pavimento betuminoso' (figura 39).




Figura 39 – Resultado da segmentação para ambos *softwares* na individualização dos carros

O delineamento dos elementos urbanos pelo algoritmo *multiresolution*, proveniente do *eCognition 8.0*, adivinha-se como sendo o que conduz à melhor base de segmentação aquando a execução da classificação. Porém, o nível de partição dos objectos poderá ter efeitos nefastos na classificação da imagem, com o algoritmo *nearest neighbor*, pois aqui poderá se perder a individualidade da forma de cada elemento urbano da paisagem e como consequência a vantagem sugerida pelo *eCognition 8.0*, de ser capaz de classificar não só pela assinatura espectral dos objectos, mas também pela sua forma, textura e contexto.

A fragmentação excessiva que apresenta poderia ser ultrapassada com a segmentação hierarquizada por níveis, optimizando a escala, e os parâmetros de cor e forma aquando o processamento.

V.2. Análise de Exactidão

Diferentes abordagens foram realizadas com o intuito de comparar a sua adequação à classificação de imagens de alta resolução, sobre a área urbana, analisando os seus pontos fortes e debilidades.

Em seguida, faz-se uma exposição dos resultados obtidos através de uma análise de exactidão global (EG) e de uma apreciação do índice de concordância Kappa

(Kappa), primeiro de uma forma geral, e só depois pelos diferentes níveis da nomenclatura proposta, 4, 3, 2 e 1. Uma pequena variação do nível 4 foi experimentada, a subtracção de uma classe, de 13 para 12, correspondente à não diferenciação da vegetação arbórea resinosa da folhosa.

Nas tabelas 13 e 14, pode-se observar os resultados obtidos para EG e para Kappa, pelos diferentes níveis.

					Número de Pontos Amostrados Aleatoriamente		
					100 Pontos Combinados	50 Lançados sobre os Segmentos	50 Lançado sobre os Objectos
CLASSIFICAÇÕES		Algoritmo	Nível	Nº Classes	Exactidão Global (%)		
1.	Pixel a Pixel	Random Forests	4	13	56.9	51.7	62.2
			3	12	60.3	55.1	65.5
			3	9	63.0	58.3	67.7
			2	4	69.8	64.5	75.1
			1	2	87.5	86.2	88.8
2.	Orientada por Segmentos	Nearest Neighbor	4	13	58.4	54.2	62.6
			3	12	61.9	57.7	66.2
		Algoritmo de Majoração	3	9	65.3	61.8	68.8
			2	4	70.6	67.4	73.8
			1	2	86.2	85.2	87.2
3.	Classificação Combinada, Pixel a Pixel agrupada por Segmentos	Random Forests	4	13	58.4	54.2	62.6
			3	12	61.9	57.7	66.2
		Algoritmo de Majoração	3	9	65.3	61.8	68.8
			2	4	70.6	67.4	73.8
			1	2	86.2	85.2	87.2
4.1	Orientada por Objectos	Multi-resolution e Nearest Neighbor	4	13	63.6	58.2	69.1
			3	12	66.5	60.8	72.2
			3	9	68.7	63.7	73.7
	Cor e Textura		2	4	75.2	69.4	80.9
			1	2	90.7	88.8	92.6
4.2	Orientada por Objectos		4	13	52.9	47.8	58.0
			3	12	55.6	50.0	61.2
			3	9	59.5	54.3	64.6
	Cor e Contexto		2	4	68.8	63.5	74.2
			1	2	89.2	88.2	90.2

Tabela 13 – Exactidão global para todos os ensaios de classificação

					Número de Pontos Amostrados Aleatoriamente		
					100 Pontos Combinados	50 Lançados sobre os Segmentos	50 Lançado sobre os Objectos
CLASSIFICAÇÕES		Algoritmo	Nível	Nº Classes	Índice de Concordância Kappa		
1.	Pixel a Pixel	Random Forests	4	13	0.53	0.47	0.59
			4	12	0.56	0.50	0.62
			3	9	0.56	0.50	0.63
			2	4	0.59	0.51	0.66
			1	2	0.75	0.72	0.77
2.	Orientada por Segmentos	Nearest Neighbor	4	13	0.55	0.50	0.59
			4	12	0.58	0.53	0.63
		Algoritmo de Majoração	3	9	0.59	0.54	0.64
			2	4	0.60	0.55	0.65
			1	2	0.72	0.70	0.74
3.	Classificação Combinada, Pixel a Pixel agrupada por Segmentos	Random Forests	4	13	0.55	0.50	0.59
			4	12	0.58	0.53	0.63
		Algoritmo de Majoração	3	9	0.59	0.54	0.64
			2	4	0.60	0.55	0.65
			1	2	0.72	0.70	0.74
4.1	Orientada por Objectos	Multi-resolution e Nearest Neighbor	4	13	0.60	0.54	0.66
			4	12	0.63	0.56	0.69
			3	9	0.63	0.56	0.70
			2	4	0.66	0.58	0.74
	Cor e Textura		1	2	0.81	0.77	0.85
4.2	Orientada por Objectos		4	13	0.49	0.43	0.54
			4	12	0.51	0.45	0.58
			3	9	0.53	0.46	0.59
			2	4	0.58	0.51	0.65
	Cor e Contexto		1	2	0.78	0.76	0.80

Tabela 14 – Valores para o Índice de concordância Kappa, para todos os ensaios de classificação

De uma forma geral, a primeira observação que se deve realçar sobre estes resultados é que os valores de EG e Kappa variam bastante consoante os pontos de amostragem. Estes foram amostrados de forma mista, 50 pontos por classe, primeiro sobre a classificação *orientada por segmentos* e depois *por objectos*, perfazendo um total de 100 pontos por classe. A diferença dos valores aferidos para EG de uma amostragem para a outra é na ordem dos 10%, diminuindo apenas quando se trata das

classificações resultantes que integram os segmentos por inteiro (2), ou em parte (3). O mesmo fenómeno se passa para os valores de Kappa, na mesma ordem de grandeza, de uma coluna para a outra observa-se os valores a mudar em cerca de uma décima; no entanto, sem atenuação notória para as classificações anteriormente referidas para EG.

Este facto, pode-se dever ao facto de os segmentos, como se observou anteriormente, não conseguirem na sua generalidade individualizar as classes pelos seus pixels de fronteira. Existindo vários pontos que estarão na fronteira dos segmentos, numa localização que levanta maior dúvida quando o aferimento dos pontos de referência. Porém, manteve-se sempre como regra classificá-los, mesmo quando estes poderiam causar algum embaraço, por estarem no limiar dos elementos urbanos. Quando estas dificuldades, tentou-se ultrapassá-la com o contexto do pixel, sobre o qual recaia o ponto, bem como com uma aproximação absoluta para ver qual a sua assinatura espectral.

Outra hipótese terá a ver com o facto de se a classificação *orientada por objectos* se provar a mais rigorosa, é natural que os pontos lançados e aferidos para referência sobre a imagem sejam por si só mais representativos das classes.

A incerteza destas questões levanta outra de maior relevância, serão os pontos de amostragem por si só capazes de se assumirem suficientes como informação de referência? Na opinião do autor, não. O embaraço causado por a informação de referência se tratar de pontos isolados, ao invés de elementos urbanos da paisagem aqui representados não só por pixels, mas também por segmentos e objectos, causa efeitos nefastos; na medida que um só pixel determina se um elemento urbano está bem ou mal classificado. Um pixel isolado não deveria poder determinar a EG de uma identificação e classificação de um elemento urbano, que pode incluir mais de 100 pixels. O sugerido como o mais correcto, do ponto de vista desta análise, para trabalhos futuros, é que estes pontos determinem apenas os elementos a serem desenhados manualmente pelo operador, e assentes como informação de referência, ao invés dos pontos aqui usados. Desta forma poder-se-ia, no ponto de vista do autor, e fundamentado por trabalho já efectuado pelas equipas do eGeo-FCSH, não só se obter uma análise de exactidão mais rigorosa, mas também validar a exactidão de um

segmento/objecto pela percentagem com que este coincidiria sobre o elemento urbano de referência. Estes impasses foram identificados aquando o processo de análise de EG e aferimento de Kappa, contudo devido à morosidade e à falta de consenso ainda existente nesta matéria, optou-se por uma via mais tradicional e testada.

Outros ensaios foram testados, e logo abandonados, por se revelarem insuficientes na representatividade dos segmentos e dos objectos. O primeiro resultou do lançamento de pontos sobre a classificação *pixel a pixel*, pelo algoritmo *random forests*, mas estes pontos acentuavam ainda mais a individualidade do pixel em detrimento da colectividade do segmento/objecto. Esta classificação devolve mais de 200.000 unidades agrupadas por pixels adjacentes da mesma classe.

Outro ensaio foi limitar o local em que os pontos de amostragem pudessem estar presentes, ou seja, criar regras adicionais para o seu lançamento com o intuito de estes não caírem nas zonas de fronteira entre segmentos/objectos, para facilitar ao operador a identificação da informação de referência. Contudo, o seu resultado iria ser enviesado e não iria permitir observar a habilidade dos classificadores nas áreas de adjacência dos segmentos/objectos, para os distinguir e categorizar.

Porém, haja todos estes quesitos em relação aos pontos de amostragem, estes são considerados válidos, pois foram amostrados aleatoriamente e aferidos de igual forma para ambas as amostragens. A sua veracidade é também confirmada pelo facto, anteriormente comentado, estes variam de igual forma, embora que com valores de grandeza diferentes, aquando a agrupação das classes por outros níveis, para todas as classificações.

Em relação aos valores aferidos para a análise de EG e Kappa, para as diferentes abordagens de classificação, verifica-se que os valores não são muito elevados, como já se seria de esperar, tendo em conta os valores apresentados nos outros estudos, no estado da arte. Porém, estes valores aumentam consideravelmente para os níveis de maior agrupação das classes, para todas as abordagens ensaiadas. O simples agrupamento da classe de vegetação arbórea, incluindo a resinosa e a folhosa, permite um acréscimo na ordem dos 3% da EG para cada classificação. A junção destas classes justifica-se na medida em que estas duas classes são de difícil distinção, sendo

facilmente confundidas. A vegetação folhosa facilmente assume uma assinatura espectral e uma textura idêntica à resinosa, dependendo da espécie em questão e de sua idade.

A classificação que apresenta maior valor de EG e Kappa, para todos os níveis, é a classificação *orientada por objectos*, obtida pelos algoritmos *multiresolution* e *nearest neighbor*, com maior relevância para a 'Cor e Textura'. Em contraposição, a classificação que apresenta menor EG e Kappa, para todos os níveis, é também obtida por *orientação aos objectos*, onde se deu maior relevo ao contexto do que à textura dos mesmos. Este facto poderá ser explicado pela falta de introdução de dados temáticos, que contextualizem os objectos no espaço. A disparidade entre as duas classificações aponta no sentido que a textura dos objectos assume maior importância aquando a simplicidade de processamento, ou seja, o algoritmo de classificação *nearest neighbor* não consegue dar resposta a estes parâmetros sem dados adicionais sobre os objectos correspondentes aos elementos urbanos. Razão pela qual esta classificação fica posta de parte, aquando a comparação com outros métodos de classificação.

Uma outra questão sobressai aquando a análise geral dos dados obtidos para as primeiras três classificações, é a sua semelhança de valores para EG e Kappa. O algoritmo de majoração proveniente do *IDRISI Taiga*, que reagrupa os *pixels* por segmentos, atribuindo aos mesmos a classe de *pixels* mais representativa no seu interior, vai provocar alterações na classificação. Ao observarmos as métricas EG e Kappa para as classificações (2) e (3) constatamos que os valores são iguais, embora a primeira tenha sido inteiramente executada por orientação aos segmentos, e a segunda primeiro classificada com aproximação ao *pixel* e só depois agrupada por segmentos. Com o intuito de tentar esclarecer qual o efeito do algoritmo de majoração para o resultado final de ambas as classificações, procedeu-se à análise de exactidão do resultado intermédio da classificação *orientada por segmentos*, ver tabela 15. Recorde-se que esta tem início na segmentação da imagem, seguindo-se a atribuição das áreas de treino pelos segmentos, sendo depois classificada ao nível do *pixel*, pelo algoritmo *nearest neighbor*, e só posteriormente reagrupada pelo algoritmo de majoração.

				Número de Pontos Amostrados Aleatoriamente		
				100 Pontos Combinados	50 Lançados sobre os Segmentos	50 Lançado sobre os Objectos
CLASSIFICAÇÕES	Algoritmo	Nível	Nº Classes	Exactidão Global (%)		
<i>Pixel a Pixel, com as áreas de treino atribuídas pelos segmentos</i> (resultado intermédio da classificação 2.)	<i>Nearest Neighbor</i>	4	13	57.5	53.2	61.7
		3	12	59.5	55.5	63.5
		3	9	60.8	56.9	64.8
		2	4	70.6	66.2	75.1
		1	2	87.4	86.6	88.2
				Índice de Concordância Kappa		
		4	13	0.54	0.49	0.58
		3	12	0.56	0.51	0.60
		3	9	0.55	0.50	0.59
		2	4	0.60	0.54	0.66
		1	2	0.75	0.73	0.76

Tabela 15 – Exactidão global e índice de concordância Kappa para o resultado intermédio da classificação *orientada por segmentos*

Verificamos que os valores, para a EG e Kappa, para o resultado intermédio da classificação *orientada por segmentos*, ainda ao nível do pixel, são similares aos obtidos pela classificação *pixel a pixel*, pelo algoritmo *random forests*. Na tabela 16, observamos os valores das métricas, para os 100 pontos amostrados.

		CLASSIFICAÇÕES	
		<i>Pixel a Pixel, Random forests</i>	<i>Pixel a Pixel, Nearest neighbor</i>
Nível	Nº Classes	Exactidão Global (%)	
4	13	57.5	56.9
3	12	59.5	60.3
3	9	60.8	63.0
2	4	70.6	69.8
1	2	87.4	87.5
		Índice de Concordância Kappa	
4	13	0.54	0.53
3	12	0.56	0.56
3	9	0.55	0.56
2	4	0.60	0.59
1	2	0.75	0.75

Tabela 16 – Exactidão global e índice de concordância Kappa para a classificação *pixel a pixel* e para o resultado intermédio da classificação *orientada por segmentos*

Os valores mesmo sendo semelhantes, não são iguais; porém, quando se submetem ao algoritmo de majoração este uniformiza as duas classificações, não se detectando diferenças entre ambas pelo análise de exactidão.

Outro ensaio foi realizado com o intuito de se tentar compreender qual o efeito do algoritmo de majoração, no reagrupamento dos pixels, de uma classificação *pixel a pixel*. Para tal, foi-se verificar quais seriam os resultados da classificação combinada resultante da abordagem *pixel a pixel* pelo algoritmo *random forests*, com o algoritmo de majoração do *IDRISI Taiga*, para outro nível de segmentação. Esta classificação foi eleita para realizar este ensaio, em detrimento do resultado intermédio (*pixel a pixel* pelo algoritmo *nearest neighbor*) da classificação *orientada por segmentos*, porque apenas se pretende fazer variar o algoritmo de majoração, independentemente das áreas de treino, como acontece na segunda referida.

O nível de segmentação já foi apresentado e discutido no subcapítulo anterior, com os parâmetros *Scale* igual a 10, Janela 2x2, WMF=0.75 e WVF=0.25 e bandas desigualmente distribuídas. Este ensaio reagrupa os pixels por um total de 11.459

segmentos, cerca de um quinto aos inicialmente ensaiados. O seu resultado visual pode-se observar na Figura 40.




Figura 40 – Resultado de um Ensaio de Classificação combinada, *pixel a pixel* agrupada por segmentos de *scale* igual a 10

A análise de exactidão foi também realizada para esta classificação, para se estimar qual a EG e o Kappa, para o nível 4 com 13 classes são estes, por ordem, 55.7% e 0.52. Estes valores pouco diferem dos anteriormente calculados para um grau de segmentação superior, 58,4% e 0.55. Este resultado vai de encontro ao discutido no subcapítulo anterior, a sobre fragmentação da imagem, aquando a diminuição do valor *scale*. De onde resultava uma maior sobre divisão dos elementos já individualizados do que na delineação de outros. No entanto, esse procedimento foi seguido no intuito de se conseguir atribuir áreas de treino mais exímias, ou seja, com menor “ruído” por parte dos segmentos adjacentes. O que daqui se conclui, que não há grandes ganhos para a EG e Kappa com a maior segmentação da imagem.

O conjunto destes ensaios, das imagens classificadas para o estudo, resultados intermédios, alternativas às mesmas, indicam a pouca diferença que existe entre a abordagem de classificação *pixel a pixel*, com a *orientada por segmentos*. Estas estão intimamente relacionadas com os dados radiométricos das imagens, a assinatura espectral é o ponto-chave deste tipo de classificações. A textura e o contexto espacial

são ignorados por estas, o seu uso em imagens de alta resolução restringe a informação que estas contêm, não conseguindo usufruir de toda a informação que estas acarretam. Os resultados obtidos sugerem que dificilmente conseguirão ser melhorados, sem acções de pós-processamento.

Terminada esta análise geral sobre os resultados, procedeu-se a uma análise comparada das diferentes abordagens de classificação; considerando apenas as primeiras 4 classificações das tabelas 13 e 14, e os valores aferidos para os pontos de amostragem combinados.

A análise de exactidão foi realizada, de forma hierarquizada, pelos diferentes níveis de agrupamento das classes, com o fim de identificar as habilidades e dificuldades dos diferentes procedimentos de classificação. Esta foi realizada, tendo como começo o Nível 4 de estratificação das classes. Na tabela 17, vem registado a exactidão do produtor (EP) e do utilizador (EU), obtida pelas matrizes de confusão de cada classificação, para cada classe, de onde facilmente se afere o erro de comissão e Omissão para cada uma, visto serem complementares em percentagem às exactidões referidas anteriormente.

A discussão, devido à quantidade de classes presentes, vai ser realizada pela mesma ordem que estão organizadas na tabela 17.

	Exactidão (%)							
	<i>Pixel a Pixel</i>		<i>Orientada por Segmentos</i>		<i>Combinada, Pixel a Pixel agrupada por Segmentos</i>		<i>Orientada por Objectos</i>	
	(1.)		(2.)		(3.)		(4.)	
	PRODUTOR	UTILIZADOR	PRODUTOR	UTILIZADOR	PRODUTOR	UTILIZADOR	PRODUTOR	UTILIZADOR
Edifícios com cobertura cerâmica	85	57	80	60	80	60	73	62
Edifícios com cobertura de betão	23	51	23	53	23	53	32	52
Edifícios com cobertura Metálica	86	88	87	80	87	80	82	81
Pistas, Campos de Ténis, Ciclovias	58	66	68	59	68	59	54	94
Relvados Sintéticos e Campos de Jogos com pavimento de betão	45	97	52	95	52	95	60	95
Pavimentos betuminosos	60	44	64	47	64	47	71	40
Passeios e outras áreas pedonais	33	46	32	40	32	40	39	58
Veg. Resinosa	41	63	42	69	42	69	46	80
Veg. Folhosa	69	30	70	33	70	33	75	49
Veg. Herbácea	67	59	71	64	71	64	76	63
Solo Exposto	54	59	58	59	58	59	68	48
Agua	99	93	91	96	91	96	95	97
Sombra	90	41	89	44	89	44	80	79

Tabela 17 - Exactidão do produtor e utilizador de cada classificação, para as classes do nível 4

EDIFÍCIOS COM COBERTURA CERÂMICA

A classe nomeada apresenta acentuada disparidade entre a EP e EU e do utilizador, variando, para inferior valor, em 11 a 28%. A classificação mais

representativa desta variação é a *pixel a pixel* (1), que por sua vez também apresenta o maior valor para a EP, com 85%, e o menor valor para a EU, com 57%. O que nos indica a pouca ocorrência de unidades erradamente classificadas nesta classe, que deveriam estar alocadas a outras. O mesmo já não se passa em relação à quantidade de unidades que deveriam estar classificadas como inclusas à classe e que ficaram erradamente distribuídas por outras classes.

Observando, no Anexo A, a matriz de confusão para a classificação (1), verificou-se que as classes que mais contribuíram para o erro de omissão, foram ‘Edifícios com cobertura de betão’, com maior incidência, e em menor e igual proporção as categorias ‘Pistas, Campos de ténis, Ciclovias’ e ‘Solo Exposto’.

A assinatura espectral da classe em questão é variável, dependendo do tipo de telha da cobertura cerâmica, passando-se o mesmo para a textura. A presença de chaminés e clarabóias, ou até mesmo de antenas, cria variabilidade na cobertura de edifícios. A reunião destas características, irá criar semelhanças com outras categorias, dificultando a classificação da imagem em todas as abordagens; incluso a classificação *orientada por objectos*, pois a forma dos edifícios é também variável.

Na figura 41, mostra-se visualmente exemplos de como esta classe varia espectralmente, podendo se assemelhar a outras classes.



Figura 41 – Amostra visual da variabilidade espectral da classe ‘Edifícios com cobertura cerâmica’, em falsa cor

As classificações (2) e (3) apresentam também, um erro de omissão superior ao de comissão, sendo o primeiro de 40% e o segundo de 20%. A classe que mais contribuiu para o erro de omissão foi ‘Edifícios com cobertura de betão’. Pela mesma razão que se discutiu anteriormente, a variabilidade espectral dentro da classe.

Veja-se o exemplo de um aglomerado de pixels difícil de classificar pertencentes à classe e os resultados de classificação para todas as abordagens, na figura 42. Verificamos que apenas a classificação *orientada por objectos* (4.) consegue classificar o aglomerado de pixels como ‘Edifícios com cobertura cerâmica’. O que nos indica a sua capacidade de ultrapassar a limitação relacionada com a assinatura espectral. Na classificação (1), observa-se uma classificação muito fiel à assinatura espectral do pixel, contudo em (3), esse efeito consegue ser minimizado em parte, aquando a agrupação por segmentos, contudo produz outros erros pela mesma razão apontada. Já em (2) há uma quebra clara entre os segmentos que delimitam o elemento, os que alternam com os correctamente classificados indicam que no resultado intermédio da classificação (*pixel a pixel*, com as áreas de treino sobre os segmentos), haveria predominância de pixels classificados individualmente alocados à classe ‘Edifícios com cobertura de betão’, logo quando agrupados pela sua frequência interna dentro dos segmentos, a classe que prevaleceu foi a anterior citada.

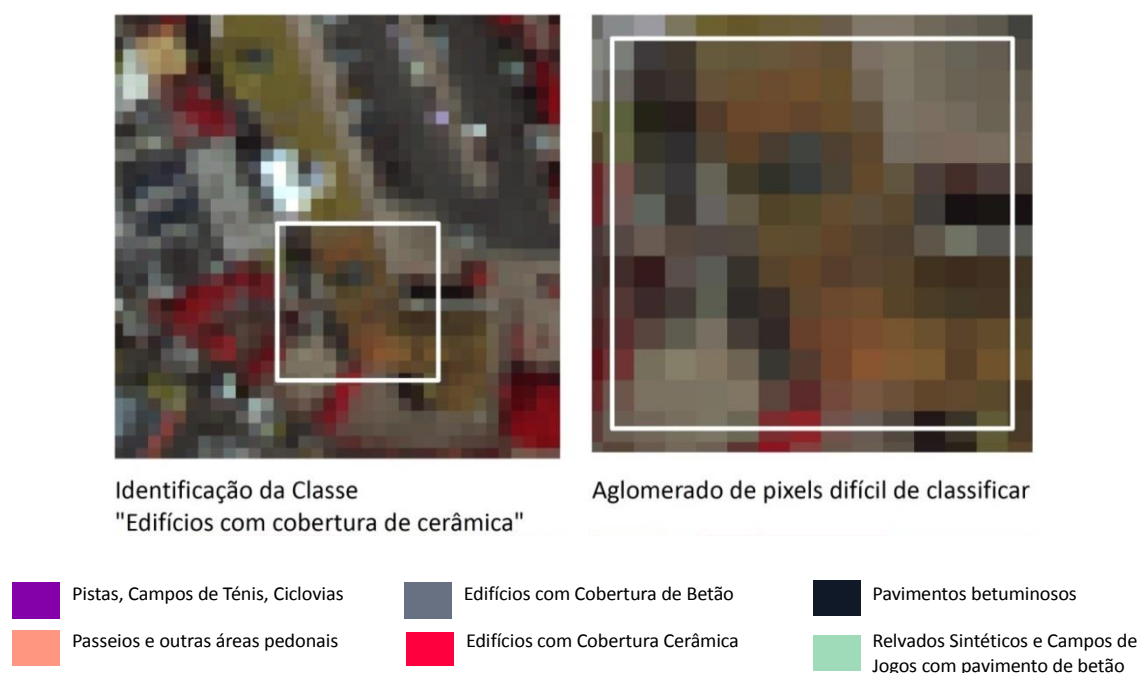


Figura 42 – Amostra visual da classificação de um elemento urbano da classe ‘Edifícios de cobertura cerâmica’, pelos diferentes tipos de abordagem






Figura 42 – Amostra visual da classificação de um elemento urbano da classe ‘Edifícios de cobertura cerâmica’, pelos diferentes tipos de abordagem (continuação)



Na classificação (4), o erro de comissão corresponde a 27 % e de omissão a 38 %, nesta há uma maior dispersão das unidades mal classificadas; para as que estão inclusas erradamente na classe temos ‘Pavimentos betuminosos’, ‘Passeios e outras áreas pedonais’ e o ‘Solo Exposto’, já para as unidades omissas, temos ‘Edifícios com cobertura de betão’, ‘Pistas, Campos de ténis, Ciclovias’ e o ‘Solo exposto’.

Anteriormente no texto foi referida a dificuldade que a similaridade espectral poderá apresentar aquando uma classificação. Agora, iremos ver exemplos de como a



textura e a forma dos elementos podem não ser suficientes para a sua diferenciação. Para tal aproveitamos primeiro erros da classificação (4), que contribuíram para o erro de comissão (figura 43).



Erro de Classificação de Inclusão dos "Pavimentos Betuminosos"



Erro de Classificação de Inclusão dos "Passeios e outras áreas pedonais"



Erro de Classificação de Inclusão dos "Solo Exposto"

Edifícios com
Cobertura Cerâmica

Figura 43 – Amostra visual de erros de classificação *orientada por objectos* da classe 'Edifícios de cobertura cerâmica'

Ao observarmos a amostra visual que incide sobre as classes que maior efeito tiveram sobre o erro de comissão, verificamos que estas não ocorrem de forma directa a uma confusão espectral, mas sim devido à texturização da imagem que dificulta a classificação da mesma pela dificuldade de individualização dos elementos urbanos.

Em relação às classes apontadas como contributo para a o erro de omissão, fez-se uma comparação visual das mesmas com a classe 'Edifícios com cobertura cerâmica', com o intuito de exhibir o porquê da confusão entre as classes (figura 44).



Semelhança com a classe "Solo Exposto"



Semelhança com a classe "Pistas, Campos de Ténis, Ciclovias"



Figura 44 – Amostra visual de elementos pertencentes à classe 'Edifícios com cobertura cerâmica' com similitude de assinatura espectral, forma e textura a outras classes, em falsa cor



Semelhança com a classe "Pistas, Campos de Ténis, Ciclovias"

Figura 44 – Amostra visual de elementos pertencentes à classe ‘Edifícios com cobertura cerâmica’ com similitude de assinatura espectral, forma e textura a outras classes, em falsa cor (continuação)

Na observação destes exemplos verifica-se o quão similares elementos de classes diferentes se assemelham não só espectralmente, mas também em textura e em forma, o que dificulta o sucesso das classificações.

EDIFÍCIOS COM COBERTURA DE BETÃO

A presente classe apresenta-se como sendo uma das mais difíceis de identificar e classificar, como já foi antes mencionado no estado da arte. Na malha urbana, vários são os elementos urbanos que apresentam betão na sua composição, conferindo uma assinatura espectral idêntica, bem como assumem geralmente uma forma também rectangular, sendo a textura muito variável pelo menos dentro da classe agora discutida. Todas as abordagens de classificação apresentam a mesma ordem de grandeza para o erro do utilizador, entre os 51 e 53%. No entanto, a classificação *orientada por objectos* (4) destaca-se das restantes por apresentar um valor de EP 9% superior às restantes, sendo este de 32%.

Na figura 45, pode-se ver como esta classe varia dentro de si em assinatura espectral, forma e textura e como se pode assemelhar à classe ‘Pavimentos Betuminosos’.






Figura 45 – Amostra visual de elementos pertencentes à classe ‘Edifícios com cobertura de Betão’ com similaridade de assinatura espectral, forma e textura à classe ‘Pavimentos Betuminosos’, em falsa cor


Em seguida, escolhemos um exemplo de um edifício, ao acaso, que poderá apresentar dificuldades aquando a sua classificação, por ter uma textura suave idêntica a alguns elementos da classe ‘Pavimentos Betuminosos’, e verificamos como cada classificação o consegue discernir e classificar (figura 46).




Identificação da Classe "Edifícios com cobertura de Betão"




Resultado da Classificação
Pixel a Pixel



Resultado da Classificação
orientada por segmentos



Resultado da Classificação
Pixel a Pixel agrupada por segmentos



Resultado da Classificação
orientada por objectos

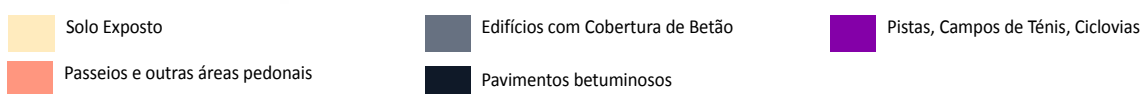




Figura 46 – Amostra visual da Classificação de um elemento urbano da classe ‘Edifícios com Cobertura de Betão’, pelos diferentes tipos de abordagem


Todas as classificações foram capazes de identificar o edifício e classificá-lo correctamente, contudo a classificação *pixel a pixel* (1) e a *orientada por objectos* (4), são as que o conseguem individualizar com maior precisão. Verificamos que as outras classificações são negligenciadas pelos segmentos resultantes do IDRISI Taiga, que não delimitou correctamente o edifício, causando entraves para uma correcta categorização.

A capacidade das abordagens em identificar os ‘Edifícios com cobertura de betão’, era expectável, pois ao observarmos as matrizes de confusão para todas as classificações (Anexo A, B, C e D), verificamos que o erro de omissão incide principalmente sobre unidades observadas que pertencem à classe ‘Passeios e outras áreas pedonais’ que estão erradamente alocadas na classe em discussão. Esta confusão é visível na figura 46, onde nas áreas internas do edifício existem áreas pedonais (dentro dos quadrados interiores) que se mostram mais difíceis de identificar e separar.


Porém, o erro de omissão incide massivamente sobre a classe ‘Pavimentos Betuminosos’, na figura 47 elegeram-se um lote de estacionamento automóvel com uma forma aproximadamente rectangular para observarmos a habilidade das classificações.




Identificação da Classe "Pavimentos Betuminosos"




Resultado da Classificação
Pixel a Pixel



Resultado da Classificação
orientada por segmentos



Resultado da Classificação
Pixel a Pixel agrupada por segmentos



Resultado da Classificação
orientada por objectos

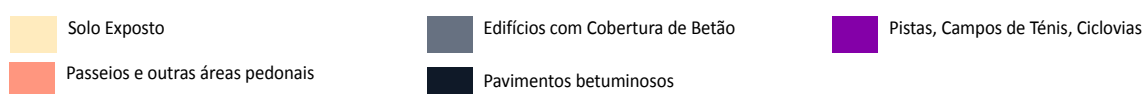


Figura 47 – Amostra visual de um elemento identificado como classe ‘Pavimentos betuminosos’, e resultados pelos diferentes tipos de abordagem

O melhor resultado é alcançado na classificação *orientada por segmentos*, que consegue categorizar correctamente o elemento, quase na sua totalidade. Contudo a classificação *pixel a pixel* e *orientada por objectos* são as que apresentam melhor nível de contorno do elemento, porém não o conseguem alocar na classe certa.


A solução para separar este tipo de elementos poderá estar na combinação deste tipo de imagens, com alto nível de detalhe, por exemplo com dados LiDAR, como já tem sido feito com sucesso, pela equipa do eGEO-FCSH.

EDIFÍCIOS COM COBERTURA DE METÁLICA

A presente classe obtém uma percentagem de exactidão tanto para o produtor como para o utilizador, para todas as classificações entre os 80-90%. Destacando-se aqui a classificação *pixel a pixel*, como a que atinge os melhores resultados. Esta classe é relativamente fácil de identificar pela sua assinatura espectral, na medida que é dissemelhante para quase todas as outras classes.

Na observação das matrizes de erro para todas as classificações, exibidas nos anexos A, B, C e D, observou-se que a maioria das unidades observadas e omissas à classe ficaram alocadas em 'Passeios e Áreas Pedonais'. Já a classe 'Edifícios com cobertura de betão' junta-se à primeira, e ganha relevância para o erro de comissão.

Na figura 48, observamos a similaridade espectral, de forma e textura desta classe se pode assemelhar a outros elementos de outras classes.



Semelhança com a classe "Passeios e Áreas Pedonais"




Semelhança com a classe "Edifícios com cobertura de betão"

Figura 48 – Amostra visual de elementos pertencentes à classe ‘Edifícios com cobertura metálica’ com similitude de assinatura espectral, forma e textura a outras classes, em falsa cor


Um pormenor que levanta alguma entropia e que contribui, por vezes, para elementos observados como ‘Passeios e Áreas Pedonais’ e que ficam classificados na classe em discussão, trata-se dos carros estacionados juntos aos mesmos (questão levantada no subcapítulo anterior); pormenor passível de se ver observado na figura 48. Alguns carros assumem um comportamento espectral muito semelhante a algumas classes, neste caso observamos o quão similar podem ser à presente classe. O nível de resolução espacial e espectral da imagem usada para o estudo, acaba por gerar este “ruído” na classificação.

Ao observarmos os valores para a EU desta classe denotou-se um valor de destaque para a classificação *orientada por objectos*, de 94%, frente às outras classificações que apresentam valores na ordem de grandeza entre 66% e 59%. Já a EP é idêntica para todas as abordagens, variando entre 54% e 59%. De forma transversal, as classes que contribuem os erros de omissão e comissão são ‘Edifícios com cobertura de Cerâmica’ e o ‘Solo Exposto’, que se assemelham espectralmente, em textura e forma, como já foi observado em parte aquando a discussão da primeira classe referida.


Vejamos uma amostra visual sobre os resultados de classificação para um elemento pertencente a esta classe, escolhido aleatoriamente, por forma a observarmos qual a capacidade de resposta de cada uma das abordagens (figura 49).




Identificação da classe "Pistas, Campos de Ténis e Ciclovias"




Resultado da Classificação
Pixel a Pixel



Resultado da Classificação
orientada por segmentos



Resultado da Classificação
Pixel a Pixel agrupada por segmentos



Resultado da Classificação
orientada por objectos

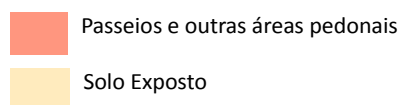




Figura 49 – Amostra visual de um elemento identificado como classe ‘Pistas, Campos de Ténis e Ciclovias’, e resultados pelos diferentes tipos de abordagem

Analisando a figura 49, observamos que tanto a classificação *orientada por segmentos*, como *por objectos*, consegue identificar e classificar com boa precisão o elemento da classe em discussão, ambas as segmentações são realizadas com sucesso, devido a serem assinaturas espectrais muito diferentes, tanto dentro do elemento como fora, o que facilita o processo. A classificação *pixel a pixel*, revela maior dificuldade, classificando parte do elemento como pertencente à classe ‘Edifício com cobertura de cerâmica’, erro esse que mantém quando combinada pelos segmentos.

RELVADOS SINTÉTICOS E CAMPOS DE JOGOS COM PAVIMENTO DE BETÃO

A presente classe revela uma EU muito elevada para todas as classificações, o que nos indica, pelos dados estimados, que as unidades observadas para esta classe estão correctamente alocadas à mesma. Contudo, o mesmo já não se passa de igual forma para a EP, que apresenta valores significativamente mais baixos, para as primeiras três classificações, (1), (2) e (3), esta varia entre 45% e 52%. A classificação que apresenta menor erro de comissão é a *orientada por objectos*, com uma EP de 60%.

Nas primeiras três classificações o erro de comissão ocorre sobretudo pela classificação de elementos pertencentes à classe ‘Sombra’ que ficaram inclusos na classe em discussão; como se constata pelas matrizes de erro nos anexos A, B e C. O que é de facto expectável, pois estas duas classes assumem, por vezes, elementos com assinatura espectral idêntica, em específico no caso dos relvados sintéticos, como se pode ver na figura 50.



Semelhança com a classe "Sombra"

Figura 50 – Amostra visual de um elemento pertencente à classe ‘Relvados Sintéticos e Campos de Jogos com pavimento de betão’ com similitude de assinatura espectral à classe ‘Sombra’, em falsa cor

O mesmo já não se passa para a classificação *orientada por objectos*, como se poder ver na matriz de Erro, no Anexo D, em que as classes que induzem ao erro de comissão para esta classe são os ‘Edifícios com cobertura de betão’ e o ‘Solo exposto’, pois estes elementos assumem não só a assinatura espectrais semelhantes, mas por vezes também a mesma forma e textura, como se pode ver na figura 51.






Figura 51 – Segunda amostra visual de um elemento pertencente à classe ‘Relvados Sintéticos e Campos de Jogos com pavimento de betão’ com similitude de assinatura espectral, forma e textura com outras classes, em falsa cor

Um exemplo de classificação para um elemento da classe em discussão é apresentado, na figura 52, à semelhança do que já foi realizado para outras classes para que se possa observar sobre uma amostra visual a capacidade das diferentes

abordagens na identificação e classificação. Nos dois elementos sugeridos para se averiguar os resultados de classificação, verificamos que um deles é classificado com igual sucesso em todas as abordagens, porém o outro mostra maior dificuldade em ser delineado e classificado, principalmente pela aproximação da classificação *orientada por segmentos*. No entanto a classificação (3) apresenta o melhor resultado, pois a abordagem do *pixel* (1) é realizada com êxito para os mesmos elementos.


Outro facto a salientar, que se denota nos resultados apresentados na figura 52, já referido anteriormente, é a sobre fragmentação da imagem que irá induzir a erros aquando a classificação, principalmente na classificação *orientada por objectos*, pois nesta abordagem a forma e a textura assumem igual importância à assinatura espectral. O excesso de divisão induz variabilidade de formas, no caso destes elementos a forma deixa de ser rectangular para estar repartida por polígonos das mais variadas formas, aumentando a probabilidade destes se identificarem com outras classes, dando espaço à confusão entre as mesmas, reduzindo a capacidade do classificador em identificá-las.




Identificação da classe "Relvados Sintéticos e Campos de Jogos com pavimento de betão"



Resultado da Classificação
Pixel a Pixel



Resultado da Classificação
orientada por segmentos



Resultado da Classificação
Pixel a Pixel agrupada por segmentos



Resultado da Classificação
orientada por objectos

 Relvados Sintéticos e Campos de Jogos com pavimento de betão	 Pavimentos betuminosos	 Vegetação Arbórea Resinosa
--	--	--

Figura 52 – Amostra visual de dois elementos identificados como classe ‘Relvados Sintéticos e Campos de Jogos com pavimento de betão’, e resultados pelos diferentes tipos de abordagem

PAVIMENTOS BETUMINOSOS

A presente classe já foi referida anteriormente na discussão da classe ‘Edifícios com cobertura de Betão’, pelas suas parecenças a nível espectral, de forma e textura e como estas podem facilmente se confundir. A EU para todas as abordagens de classificação é idêntica, variando entre 40 e 47%, sendo a razão para o erro de omissão também semelhante. Várias foram as unidades observadas como sendo pertencentes a ‘Pavimentos Betuminosos’ e erradamente classificadas como ‘Edifícios com cobertura de betão’ (ver anexo A, B, C e D). Porém, o erro de comissão tem origem em outras classes; para as primeiras três classificações, este valor varia de 36 a 40%, sendo a classe ‘Sombra’ a que apresenta o maior número de unidades observadas que estão erradamente alocadas à classe em questão, devido novamente à similaridade espectral entre ambas. A forma e a textura também são idênticas à, contudo parece não causar entropia na classificação *orientada por objectos*, onde o erro de comissão é inferior às anteriores, com um valor de 29%, e onde nenhuma classe parece contribuir com maior destaque para o mesmo. Na figura 53, podemos observar as características de semelhança entre as classes.



Similaridade espectral à classe "Sombra"

Figura 53 – Amostra visual de um elemento pertencente à classe ‘Pavimentos Betuminosos’ com similitude de assinatura espectral à classe ‘Sombra’, em falsa cor

PASSEIOS E OUTRAS ÁREAS PEDONAIS

A classificação com maior valor para a exactidão do produtor e do utilizador é a *orientada por objectos*, com valores de 39% e de 58%, destacando-se de todas as outras. O erro de comissão e omissão deve-se principalmente, como se observa no anexo D, às classes relativas aos edifícios; a que se deve o facto de os passeios por vezes serem muito estreitos e não ficarem individualizados e sim incluídos na bordadura dos mesmos.

No entanto para as outras três classificações, (1), (2) e (3), temos transversalmente que a classe que mais contribui para o erro de omissão é a ‘Edifícios com cobertura de betão’, bem como para o erro de comissão. Porém para este último acresce a classe ‘Solo Exposto’. Na figura 54, observamos a similaridade espectral que estas classes podem assumir.




Figura 54 – Amostra visual de um elemento pertencente à classe ‘Passeios e outras áreas pedonais’ com similitude de assinatura espectral a outras classes, em falsa cor

VEGETAÇÃO ARBÓREA RESINOSA, VEGETAÇÃO ARBÓREA FOLHOSA E VEGETAÇÃO HERBÁCEA

As 3 classes são discutidas em conjunto, devido à interligação que apresentam e às semelhanças que as unem, diferenciando-se com facilidade de todas as outras classes que classificam a imagem, salvo rara excepção. A principal dificuldade para os diferentes métodos de classificação reside em individualizá-las e separá-las entre si, sem embaraço. Na figura 55, podemos observar um exemplo visual de cada classe, analisando quais as suas parecenças.



Figura 55 – Amostra visual de elementos pertencente às classes de vegetação, em falsa cor

Na tabela 18 temos a selecção de pixels observados para cada classe, quando intersectados pelos pixels classificados para cada uma. Estes valores foram retirados das matrizes de erro respectivas a cada classificação, para que se possa observar mais atentamente como estas três classes são distinguidas em cada abordagem.

		Pixel a Pixel			Orientada por Segmentos		
		(1.)			(2.)		
		PIXELS OBSERVADOS					
		Veg. Arb. Resinosa	Veg.Arb. Folhosa	Veg. Herbácea	Veg. Arb. Resinosa	Veg.Arb. Folhosa	Veg. Herbácea
PIXELS CLASSIFICADOS	Veg. Arb. Resinosa	41	42	9	45	44	7
	Veg.Arb. Folhosa	2	38	15	2	42	14
	Veg. Herbácea	3	29	71	3	14	78
EXACTIDÃO DO PRODUTOR (%)		42	70	71	42	70	71
EXACTIDÃO DO UTILIZADOR (%)		63	30	59	69	33	64
		Combinada, Pixel a Pixel agrupada por Segmentos			Orientada por Objectos		
		(3.)			(4.)		
		PIXELS OBSERVADOS					
		Veg. Arb. Resinosa	Veg.Arb. Folhosa	Veg. Herbácea	Veg. Arb. Resinosa	Veg.Arb. Folhosa	Veg. Herbácea
PIXELS CLASSIFICADOS	Veg. Arb. Resinosa	45	44	7	52	34	9
	Veg.Arb. Folhosa	2	42	14	3	63	18
	Veg. Herbácea	3	14	78	1	12	76
EXACTIDÃO DO PRODUTOR (%)		42	70	71	46	75	76
EXACTIDÃO DO UTILIZADOR (%)		69	33	64	80	49	63

Tabela 18 – Intersecção das classes relativas à ‘Vegetação’, para cada abordagem

Na observação da mesma verificamos que a classificação que apresenta melhor exactidão a nível do produtor e utilizador é a classificação *orientada por objectos*. Porém um erro de comissão que ocorre transversalmente por todas as abordagens é a classificação da ‘Vegetação arbórea folhosa’ na classe da ‘Vegetação arbórea resinosa’. Estes dois elementos assumem semelhante forma e textura, sendo a assinatura espectral por vezes quase igual e outras vezes distinta. Este facto deve-se


principalmente à vegetação folhosa, que varia no seu comportamento espectral dependendo da espécie, da idade das árvores e também da fisionomia da folha. Razão por a qual se resolveu apurar qual a exactidão tanto para o produtor e utilizador, bem como o Kappa, quando estas duas classes ficam agrupadas numa só, os resultados são óbvios e verifica-se um aumento universal para todas as classificações.

A confusão ente as classes ‘Vegetação arbórea folhosa’ e ‘Vegetação Herbácea’ também acontece, assumindo certa relevância tanto para o erro de omissão como para o erro de comissão. A razão aqui é idêntica à anteriormente referida, embora em muito menor escala, e volta a ter o seu foco na variabilidade de textura e assinatura espectral que a ‘Vegetação arbórea folhosa’ assume; quando as árvores são mais novas e as suas folhas são menos cerosas, apresentando uma textura mais suavizada, visualmente assemelha-se em muito à classe ‘Vegetação Herbácea’.


Na figura 56 observamos os resultados de todas classificações para a zona Norte do Jardim do Campo Grande, com o intuito de verificarmos quais os resultados de segmentação bem como de classificação. Verificamos que a segmentação obtida pelo algoritmo do *eCognition 8.0*, delineia a copa das árvores sem as subdividir em demasia, bem como a vegetação herbácea, conseguindo depois melhores resultados em termos de classificação quando comparados aos aferidos pela classificação *orientada por segmentos*. Na classe ‘Vegetação herbácea’ é clara sobre a optimização dos diferentes processos de classificação, onde se verifica a uniformização da mesma.




Identificação das classes "Vegetação Arbórea Resinosa", "Vegetação Arbórea Folhosa" e "Vegetação Herbácea".



Resultado da Classificação
Pixel a Pixel



Resultado da Classificação
orientada por segmentos



Resultado da Classificação
Pixel a Pixel agrupada por segmentos



Resultado da Classificação
orientada por objectos

Figura 56 – Amostra visual sobre os resultados de Classificação das classes de 'Vegetação' pelos diferentes tipos de abordagem

SOLO EXPOSTO

Esta classe já foi várias vezes referida anteriormente por se confundir com outras classes, em termos de assinatura espectral, forma e textura. Nas matrizes de erro verificamos que várias são as classes que contribuem para o seu erro de omissão, contudo o erro de comissão já é mais reduzido por haver menos dispersão das unidades classificadas para a classe. O valor máximo de EG obtido é de 68% e é conquistado pela classificação *orientada por objectos*, este valor diminui para valores entre 54 e 59% para as outras classificações. O erro de omissão é igual para as classificações (1), (2) e (3), sendo este de 41% e o pior valor é novamente atingido por oposição na (4), com 52%.

ÁGUA

A classe 'Água' destaca-se de todas as outras pelo nível de exactidão do produtor e do utilizador serem as mais altas. Na classificação *pixel a pixel*, pelo algoritmo *random forests* a EP atinge os 99%, este valor decresce para 95% para a classificação *orientada por objectos*, e para 91% para as outras duas. No entanto, estes valores já eram algo expectáveis, pois como é um elemento pouco presente na imagem, as áreas de treino, bem como os pontos de amostragem recaíram muito sobre a mesma área da imagem, o que pode ter enviesado um pouco este resultado. Não nos esqueçamos que este elemento é muito semelhante a tantos outros na paisagem urbana, principalmente a nível de assinatura espectral, devendo ser facilmente confundível com as classes 'Sombra' e 'Relvados Sintéticos (...)', 'Pavimentos Betuminosos'.

SOMBRA

A classe 'Sombra' tem a particularidade de apresentar valores de EP, na ordem dos 79 a 90% para todas as classificações. Contudo, o mesmo já não se passa para a EU, onde para as três primeiras classificações este passa para metade, só conseguindo manter a mesma ordem grandeza para a classificação *orientada por objectos*, com um valor 80%.

O erro de omissão para as primeiras três classificações deve-se ao facto de esta classe se confundir espectralmente com os ‘Pavimentos betuminosos’ e os ‘Relvados Sintéticos e Campos de Jogos com Pavimento de betão’, o que se comprova pelas matrizes de erro, apresentadas nos anexos A, B e C. O mesmo já não é visível para a classificação *orientada por objectos* (4). Observemos a figura 57, onde a classe ‘Sombra’ para esta classificação é apresentada (em branco) sobre toda a imagem em falsa cor.



Figura 57 – Resultado para a classificação *orientada por objectos* da imagem para a classe ‘Sombra’

Denotamos que este resultado assume como que um delineamento para todos os elementos sobre-elevados da malha urbana presentes na imagem do caso de estudo.

Terminada a análise de cada classe para o nível 4, iremos agora observar quais os valores de exactidão obtidos para os níveis 3, 2 e 1 da hierarquia da nomenclatura proposta. Iniciemos esta análise pelo nível 3 até ao nível 1.

	Exactidão (%)							
	<i>Pixel a Pixel</i>		<i>Orientada por Segmentos</i>		<i>Combinada, Pixel a Pixel agrupada por Segmentos</i>		<i>Orientada por Objectos</i>	
	PRODUTOR	UTILIZADOR	PRODUTOR	UTILIZADOR	PRODUTOR	UTILIZADOR	PRODUTOR	UTILIZADOR
Edifícios	62	73	62	75	62	75	66	72
Infra-estruturas Desportivas	49	83	57	79	57	79	57	94
Pavimentos betuminosos	60	44	64	47	64	47	71	40
Passeios e outras áreas pedonais	33	46	32	40	32	40	39	58
Veg Arbórea	79	64	80	69	80	69	77	79
Herbácea	67	59	71	64	71	64	76	63
Solo Exposto	54	59	58	59	58	59	68	48
Água	99	93	91	96	91	96	95	97
Sombra	90	41	89	44	89	44	80	79

Tabela 19 – Análise de exactidão para as classes do nível 3

Neste Nível, temos os ‘Edifícios agrupados’, bem como as ‘Infra-estruturas desportivas’ o que não tem relação directa com o aumento da exactidão do produtor, nem do utilizador, pois estas classes individualizadas assumem uma maior similitude com outras classes, fora deste agrupamento. O mesmo já não se passa para a ‘Vegetação Arbórea’, como já tínhamos discutido anteriormente e verificado que a sua junção resulta no aumento das métricas de exactidão, bem como para o Kappa.

No Nível 2, tabela 20, o agrupamento de classes é mais abrangente, e reúne algumas classes com características visuais idênticas, como é o caso das superclasses ‘Edifícios e Infra-estruturas desportivas’ e ‘Não Vegetação’ onde se verifica um aumento de exactidão. O mesmo já não se passa aquando a reunião dos eixos de

circulação que de acordo a sua dissemelhança continuam com valores de exactidão tanto para o produtor, como para o utilizador, na ordem dos 50%. Contudo o oposto se passa para a superclasse ‘Vegetação’, que reunindo as 3 classes que a diferenciam, os valores de exactidão atingem os valores mais altos na classificação *orientada por objectos*, com valores de 90% para o produtor e 95% para o utilizador.

Exactidão (%)								
	<i>Pixel a Pixel</i>		<i>Orientada por Segmentos</i>		<i>Combinada, Pixel a Pixel agrupada por Segmentos</i>		<i>Orientada por Objectos</i>	
	PRODUTOR	UTILIZADOR	PRODUTOR	UTILIZADOR	PRODUTOR	UTILIZADOR	PRODUTOR	UTILIZADOR
Edifícios e Infra-estruturas Desportivas	63	79	65	80	65	80	70	82
Eixos de Circulação	50	48	52	48	52	48	57	52
Vegetação	96	80	90	79	90	79	90	85
Não Vegetação	75	63	77	66	77	66	82	73

Tabela 20 – Análise de exactidão para as classes do nível 2

No nível 1 de agrupamento, por 2 superclasses apenas, ‘Urbano’ e do ‘Não Urbano’ os valores de EG e Kappa atingem novamente os seus valores máximos para a classificação *orientada por objectos*, são estes, 90.7% e 0.81, pela mesma ordem. Em relação às outras classificações a proporção também se mantém, para as classificações 2 e 3, com iguais valores para EG igual a 86.2% e Kappa 0.72, os valores para a classificação *pixel a pixel* conseguem aqui ser ligeiramente superiores com resultados para as mesmas métricas de 87.5% e 0.75. O aumento destes valores pelos vários níveis de agrupação é idêntico, e para as diferentes classificações, sugere que as diferentes abordagens terão encontrado o mesmo tipo de problemas na distinção entre classes.

Os resultados aferidos no Nível 1, para a Exactidão do utilizador e do produtor vêm esquematizados na Tabela 21.

Exactidão (%)								
	<i>Pixel a Pixel</i>		<i>Orientada por Segmentos</i>		Combinada, <i>Pixel a Pixel</i> agrupada por Segmentos		<i>Orientada por Objectos</i>	
	PRODUTOR	UTILIZADOR	PRODUTOR	UTILIZADOR	PRODUTOR	UTILIZADOR	PRODUTOR	UTILIZADOR
Urbano	83	96	82	93	82	93	88	95
Não Urbano	95	79	91	79	91	79	94	86

Tabela 21 – Análise de exactidão para as classes do nível 1

V.3 Reflexão Geral a partir dos Resultados

A classificação *orientada por objectos* destaca-se das 3 primeiras, não só pela evidência dos valores de exactidão global (EG) e índice de concordância (Kappa), mas também por deixar um leque de opções possíveis de serem executadas, com o intuito de melhorar os seus resultados. Usando as mesmas áreas de treino, e os mesmos objectos individualizados no processo de segmentação, realizou-se um breve ensaio sobre a classificação da imagem, com o algoritmo *nearest neighbor* e evidência para a ‘Cor e Textura’, mas agora hierarquizando a nomenclatura de outra forma. Neste ensaio, primeiro irá se separar as classes inclusas na classe ‘Vegetação’ das de ‘Não Vegetação’, a organização da nomenclatura pode-se observar na figura 58.




Figura 58 - Nomenclatura proposta para o ensaio


A análise de exactidão foi também executado para esta classificação, contudo não se obtiveram melhores resultados, como se pode observar para os valores de EG e Kappa, 61.4% e 0.58 *versus* os obtidos anteriormente, resultantes da separação das classes ‘Urbano’ do ‘Não Urbano’, onde os valores para EG e Kappa são de 63.6% e 0.60 (tabela 22). Contudo, esta variação é muito reduzida, não tem significado estatístico para se afirmar que uma classificação é melhor que outra; terá mais

sentido, concluir que a classificação obtida é consistente, pois fazendo variar as classes na hierarquia estabelecida por 4 níveis, esta mantém os mesmos valores.

				Número de Pontos Amostrados Aleatoriamente		
				100 Pontos Combinados	50 Lançados sobre os Segmentos	50 Lançado sobre os Objectos
CLASSIFICAÇÕES	Algoritmo	Nível	Nº Classes	Exactidão Global (%)		
Orientada por Objectos Cor e Textura	<i>Multiresolution e Nearest Neighbor</i>	4	13	61.4	56.8	66.0
		3	12	64.8	59.8	69.8
		3	9	63.0	58.3	67.7
		2	4	69.8	64.5	75.1
		1	2	87.5	86.2	88.8
				Índice de Concordância Kappa		
		4	13	0.58	0.53	0.63
		3	12	0.61	0.55	0.67
		3	9	0.56	0.50	0.63
		2	4	0.59	0.51	0.66
		1	2	0.75	0.72	0.77

Tabela 22 – Exactidão global e índice de concordância Kappa para o resultado intermédio da classificação *orientada por segmentos*

Um breve estudo é também realizado sobre a entropia que os diferentes processos de segmentação podem ter aquando a classificação. Para tal foi eleita uma amostra visual sobre a classe de ‘Edifícios com cobertura cerâmica’, a escolha deste exemplo recai sobre a variabilidade de forma que estes edifícios podem ter; com o propósito de verificar qual o resultado para as diferentes classificações aquando a variabilidade de formas. Os resultados apresentam-se na figura 59.



Amostra da imagem em Falsa Cor



Resultado da Classificação
Pixel a Pixel



Resultado da Classificação
orientada por segmentos



Resultado da Classificação
Pixel a Pixel agrupada por segmentos



Resultado da Classificação
orientada por objectos






Figura 59 – Segunda amostra visual da classificação de um elemento urbano da classe ‘Edifícios de cobertura cerâmica’, pelos diferentes tipos de abordagem

Desta amostra visual verificamos que as classificações que melhores resultados apresentam no delineamento e classificação dos ‘Edifícios com cobertura cerâmica’, são as classificações *pixel a pixel* e *orientada por objectos*. No entanto a primeira, apresenta maior “ruído” pelo grão que a imagem apresenta, e quando é reagrupada pelos segmentos perde um pouco a forma do edifício, tanto para o em forma de estrela, como para o que se assemelha a um H. Em relação à abordagem por segmentos, o delineamento não é tão “fino” como o resultante para a orientação por objectos, como podemos na figura 60.




Resultado da Segmentação
orientada por segmentos (IDRISI Taiga)



Resultado da Segmentação
orientada por objectos (eCognition 8.0)

Figura 60 – Amostra visual da segmentação executada para a classificação *orientada por segmentos e por objectos*, alusiva à classe ‘Edifícios com cobertura cerâmica’

Novamente verificamos que o excesso de fragmentação negligencia a classificação, porém verifica-se que a segmentação executada pelo algoritmo do *IDRISI Taiga* continua a assumir erros no delineamento. Na segmentação do *eCognition 8.0*, esta assume um contorno quase perfeito em torno dos edifícios, talvez não sendo necessário este nível de segmentação que reparte em demasia os elementos. Verifique-se na figura 61, o delineamento comparado para uma *scale* de 30 com, a levada a cabo na presente classificação, *scale* 15.



Resultado da Segmentação com *scale 15*
orientada por *objectos* (*eCognition 8.0*)



Resultado da Segmentação com *scale 30*
orientada por *objectos* (*eCognition 8.0*)

Figura 61 – Amostra visual da segmentação executada para diferentes valores de *scale* no *eCognition 8.0*, alusiva à classe ‘Edifícios com cobertura cerâmica’

Como se pode observar o delineamento dos *objectos* continua a estar correcto, mantendo-se mais exímio para o edifício em forma de H. Acredita-se que a classificação poderia ser melhorada no *eCognition 8.0*, com a minimização do problema de excesso de fragmentação dos elementos, através do uso de diferentes escalas na individualização dos *objectos* de cada classe.

Um hipótese sugerida para trabalhos futuros, seria realizar o processamento no *eCognition 8.0*, pela segmentação do algoritmo *multiresolution* nos diferentes níveis de hierarquia, segundo diferentes parâmetros de optimização, dependentes das unidades da imagem que se pretendam individualizar. Ou seja, estas depois de individualizadas e classificadas, caso houvesse interesse em as subdividir novamente, os segmentos internos de cada categoria poderiam ser dissolvidos, para voltar a segmentar segundo as características dos novos elementos que delas fazem parte. Este método poderia ocorrer sucessivamente até se ter a imagem categorizada pelas classes pretendidas. Por exemplo, a vegetação, salvo raras excessões, apresenta uma assinatura espectral muito diferente dos outras unidades da imagem, neste caso não seria necessário um valor para a escala tão elevado para a delimitar, o que diminuiria o número de *objectos* individualizados na imagem. Bem como, para uma melhor performance da

segmentação dar-se-ia maior relevância ao parâmetro de cor em detrimento da textura. No seguimento deste raciocínio, com a vegetação já individualizada poderia-se, com o intuito de a diferenciar em arbórea ou herbácea, otimizar os parâmetros de outra forma. Ou seja, primeiro poderia se proceder à dissolução dos segmentos separados e classificados como vegetação, para se executar de novo a segmentação, o nível de pormenor aqui seria superior e haveria interesse em diminuir o tamanho da escala, bem como dar mais ênfase à textura do que à cor, pois a vegetação arbórea contempla pixels de várias tonalidades de vermelho, sendo muito texturizada em contraposição à vegeta herbácea que tem uma textura bem mais suavizada.

CONCLUSÕES

A dissertação focou-se no desenvolvimento da análise comparada da segmentação e classificação *orientada por segmentos* e *por objectos* de dados de satélite de muito alta resolução espacial e espectral.

A experimentação efectuada sobre os dados revelou:

- a) A elevada adequabilidade da legenda hierárquica ao processo de classificação de dados, quer quanto ao número quer quanto ao tipo de classes. Esta considera quatro níveis de agregação das mesmas, sendo que no nível 4 estas se encontrem individualizadas em 13 classes referentes ao tipo de cobertura. O nível de detalhe da imagem permite um maior número de classes.
- b) A muito alta resolução espacial da imagem permite visualizar com detalhe cada objecto que compõe cada classe. Por exemplo, esta permite uma detalhada descrição do topo dos edifícios, o que por vezes dificulta o processamento. O topo de alguns edifícios com cobertura cerâmica é possível visualizar as chaminés com parte da cobertura de betão; facto que introduz confusão aquando a classificação da imagem, pois estes pixels são inclusos da classe referida e não da classe edifícios com cobertura de betão.
- c) Os diferentes processos de classificação da imagem, (*pixel a pixel* pelo algoritmo *random forests*, *orientada por segmentos* pelo algoritmo do IDRISI Taiga, e posteriormente classificados os segmentos pelo *nearest neighbor* e *random forests*, e a *orientada por objectos* pelo algoritmo *multiresolution* do *eCognition 8.0* e classificados os objectos também pelo *nearest neighbor*), revelaram uma eficácia equiparável, segundo os parâmetros determinados. Contudo, a classificação *orientada por objectos* revelou maior eficácia na discriminação dos elementos urbanos. As classificações testadas baseadas nesta abordagem podem ser claramente melhoradas, enquanto as classificações *pixel a pixel* já estão perto do seu limite de eficácia. O excesso de fragmentação dos elementos urbanos, que tem lugar com o algoritmo *multiresolution* no *eCognition 8.0*, afecta a posterior classificação da imagem. Este facto pode ser minimizado com a hierarquização da segmentação da imagem, alternando os parâmetros de

acordo com cada classe, para uma adequada individualização dos objectos. Em *IDRISI Taiga*, os parâmetros também podem ser ainda mais testados, fazendo variar os valores dados aos parâmetros. Contudo, ficará sempre aquém do *eCognition 8.0*, no que se trata a imagens de alta resolução espacial, pois tem dificuldade na individualização dos elementos urbanos mais detalhados: os seus parâmetros de origem radiométrica apenas, não têm em conta os factores contextuais dos objectos como o algoritmo do *eCognition 8.0*. A classificação *pixel a pixel* pelo algoritmo *random forests* foi também bem conseguida. Contudo, este algoritmo poderoso poderia ainda ser experimentado e aplicado a uma classificação *orientada por objectos*.

- d) É decisivo usar dados *WorldView-2* multitemporais. A utilização simultânea de uma imagem de verão, como é o caso, e de uma imagem de fim de inverno ou Primavera, permitiria anular muita da confusão espectral existente entre solo a descoberto (vazios urbanos, taludes de vias de comunicação, áreas com coberto herbáceo – com clorofila no final do Inverno e Primavera e coberto seco no verão) e áreas edificadas.
- e) A introdução de dados 3D (como por exemplo LiDAR ou altura dos edifícios a partir de cartografia digital) permitiria reduzir a confusão que não se consegue anular mesmo quando se trabalha com dados multitemporais. As classes com cobertura de betão podem se confundir entre as mesmas, um edifício com cobertura de betão pode assumir a mesma forma que um campo de jogos com pavimento de betão, para além de terem assinaturas espectrais semelhantes.

Os níveis de exactidão registados levam-nos a concluir que:

- a) A exactidão global e o índice de concordância Kappa aumentam seus valores à medida que se agrupam as classes para os outros níveis da nomenclatura hierarquizada. A classificação com maior valor para a EG e Kappa é a orientada por objectos, considerando a ‘Cor e Textura’, com valores entre os 63.6 e 90,7% e os 0.60 e 0.81, respectivamente. As outras classificações obtiveram valores muito idênticos que variam entre os 56.9% e 87,5% para EG e Kappa e 0.53 e 0.72 (Cf. Capítulo V).
- b) Os resultados descritos em a) são fortemente dependentes do tipo de amostragem que se utilizou. A amostragem foi aleatória, tendo sido

lançados 50 pontos por cada classe, sobre a classificação de imagem orientada por segmentos e outros 50 pela orientada por objectos, por forma a garantir a representatividade das classes. Esta amostragem baseada numa amostra de pontos parece favorecer os valores da exactidão. Na realidade, quando se realizou a amostragem pontual verificou-se que esta era inadequada para se fazer uma correcta avaliação da exactidão. Um ponto representa um pixel, e não um conjunto de pixels. Este pixel pode estar mal classificado individualmente, contudo pode estar correctamente categorizado em grande parte do segmento ou do objecto. Problema este que aumenta aquando o ponto de amostragem recai sobre um pixel de fronteira.

- c) Faça ao exposto na alínea b) foram realizados testes utilizando como informação de referência a obtida por análise visual de imagem¹ e utilizando a mesma legenda. Para tal falta replicar os testes para diferentes partes da cidade, e até mesmo replicar para a totalidade da imagem por forma a avaliar a influência do tipo de amostragem nos valores da exactidão.

As melhorias de procedimentos de processamento digital de imagem e de análise de exactidão que podemos apontar são:

- a) Maior variação dos parâmetros de segmentação, de tolerância de similaridade e de tamanho da vizinhança, no *IDRISI Taiga*.
- b) Maior desenvolvimento da experimentação com segmentação com *eCognition 8.0*.

Os processamentos de imagem realizados na presente dissertação, podem ser explorados e melhorados, com o conhecimento mais aprofundado dos algoritmos quer de classificação *de pixel a pixel*, quer, sobretudo, dos referentes à segmentação de imagem e à criação de objectos.

¹ Foi efectuada a análise visual de imagem, utilizando a mesma legenda e digitalização manual.

BIBLIOGRAFIA

- An, K., Zhang, J., Xiao, Y., 2007. Object-oriented Urban Dynamic Monitoring. *Chines Geographical Science* 17 (3), 236-242.
- Bhaskaran, S., Paramananda, S., Ramnarayan, M., 2010. *Applied Geography* 30, 650-665.
- Blaschke, T., Strobl, J., 2001. *Interfacing Remote Sensing and GIS*.
- Breiman, L. (2001). Random Forests. *Machine Learning* 45, 5-32.
- Brovelli, M.A., Crespi, M., Fratarcangeli, F., Giannone, F. Realini, E., 2008. Accuracy assessment of high resolution satellite imagery orientation by leave-one-out method. *ISPRS Journal of Photogrammetry & Remote Sensing* 63, 427-440.
- Carleer, A. P., Debeir, O., Wolff, E., 2005. Assessment of very high spatial resolutionsatellite images segmentations, *Photogrammetric Engineering and Remote Sensing*, in press.
- ChenJian e XiangLi, 2009. The study of Object-Oriented Classification, Method of Remote Sensing Image. The 1st International Conference on Information Science and Engineering.
- Chuvieco, E. S., 2002. Teledetección ambiental, La observación de la Tierra desde el espácio. Ariel Ciencia.
- Congalton, R., Green, K., 1999. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practises*. CRC Press, Taylor & Francis Group.
- Cutler, R., Edwards, T. C., Beard, K. H. Cutler, A., Hess, K. T., Gibson, J., Lawler, J. J., 2007. Random Forests For Classification in ecology. *Ecology* 88 (11), 2783-2792.
- Pinho, C. M. D., Fonseca, L. M. G., Korting, T. S., Almeida, C. M., Kux, J. H., 2012.. Land-Cover Classification of na intra-urban environment using high-resolution images and object-based image analysis. *International Journal of Remote Sensing* 33 (19), 5973-5995.
- Eastman, J. R., 2009. *IDRISI Taiga – Guide to GIS and Image Processing*. Clark Labs. IDRISI Production. Clark University.

Frauman, E., Wolff, E., 2005. Segmentation of very high spatial resolution satellite images in Urban areas for Segments-based Classification. Institut de Gestion de l'Environnement et d'Aménagement du Territoire, Université Libre de Bruxelles.

Freire, S., Santos, T., Fonseca, A., Gomes, N., Afonso, N., Tenedório, J. A., 2011. Extracção de arruamentos em áreas urbanas a partir de imagens de satélite com alta resolução espacial e dados LiDAR. VII Conferência Nacional de Cartografia e Geodesia. Lisboa: LIDEL. (In press).

Foody, G. M., 2009. Sample size determination for image classification accuracy assessment and comparison, *International Journal of Remote Sensing*, 30:20, 5273-5291.

Gislason, P. O., Benediktsson, J.A, Sveinsson, 2005. Random Forest for Land Cover Classification. *Pattern Recognition Letters* 27, 294-300.

Hand, D. J., 1981. Discrimination and classification. New York: John Wiley and sons.

Haralick, R.M., K. Shanmugam and I. H. Dinstein (1973). Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, 3, 610-621.

Hughes, G. F., 1968. On the mean accuracy of statistical pattern recognizers, *IEEE Transactions on Information Theory* (14), 55-63.

Lillesand, T. M., & Kiefer, R. W., 2000. Remote Sensing and image interpretation. 4th Edition. New York: Kiefer Wiley and sons.

Lucier, A., Stein, A., Fisher, P. F., 2005. Texture-based segmentation of high-resolution remotely sensed imagery for identification of fuzzy objects. *International Journal of Remote Sensing* 26 (14), 2917-2936.

Ma, H., Zhang, C., Yang, S., Xu, J., 2009. Object Oriented Information Extraction from High Resolution Remote Sensing Imagery. *IEEE*.

Niel, T. G. V., McVicar, T.R., Datt, B., 2005. On the relationship between training sample size and data dimensionality: Monte Carlo Analysis of broadband multi-temporal classification. *Remote Sensing of Environment* 98, 468 – 480.

Pal, M., Mather, P. M., 2003. An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sensing of Environment* 86, 554-565.

- Salehi, B., Zhang, Y., Zhong, M., Dey, V., 2012. Object-Based Classification of Urban Areas Using VHR Imagery and Height Points Ancillary Data. *Remote Sensing* 4, 2256-2276.
- Santos, T., Freire S., Fonseca A., Tenedório J. A., 2010. Producing a building change map for urban management purposes. *Proceedings of 30th EARSeL Symposium*. Paris, France, 31 May – June 3, 2010.
- Santos, T., Freire, S., Tenedório, J.A., Fonseca, A., 2010. Extração de Edifícios em áreas densas com imagens Quickbird e dados LiDAR. *Projecto Geosat*. (in press).
- Schroff, F., Criminisi, A., Zisserman, A., 2008. Object class Segmentation using Random Forests. *British Machine Vision Conference (BMVC)*, 1-4 Sep 2008, Leeds, UK.
- Van der Sande, C. J., de Jong, S. M., de Roo, A. P. J., 2003. A segmentation and classification approach of IKONOS-2 imagery for land cover mapping to assist risk and flood damage assessment. *International Journal of Applied Earth Observation and Geoinformation* 4, 217-229.
- Weng, Q., & Quattrochi, D. A., 2006. *Urban Remote Sensing*. CRC Press/Taylor and Francis.
- Zhou, W., Troy, A., 2008. An object-oriented approach for analyzing and characterizing urban landscape at the parcel level. *International Journal of Remote Sensing* 29 (11), 3119-3135.

LISTA DE FIGURAS

Figura 1	Enquadramento Área de Estudo.....	7
Figura 2	Correspondência entre classes.....	15
Figura 3	Passos de uma classificação supervisionada.....	17
Figura 4	Passos da segmentação da imagem e posterior classificação.....	18
Figura 5	Matriz de Confusão, sua organização e cálculo.....	27
Figura 6	Bandas do Satélite <i>WorldView-2</i>	31
Figura 7	Histograma com as 8 bandas do espectro electromagnético, presentes na imagem do estudo de caso.....	32
Figura 8	Delimitação da área do estudo de caso.....	33
Figura 9	Processamento da classificação não Supervisionada <i>IsoData</i>	34
Figura 10	Resultado da classificação não supervisionada <i>IsoData</i>	34
Figura 11	Nomenclatura proposta por Níveis de Reconhecimento.....	36
Figura 12	Fluxograma do processo de atribuição e exportação das áreas de treino	44
Figura 13	<i>Script</i> R comentado, onde se determinada a melhor combinação das variáveis	44 e 45
Figura 14	<i>Script</i> R comentado, onde são atribuídas as classes da imagem e a proporção de votos para cada uma.....	45, 46 e 47
Figura 15	<i>Script</i> usado no IDL+ENVI de onde resulta a Imagem Classificada	48 e 49
Figura 16	Fluxograma do Processamento final no ENVI, identificação de cada classe	50
Figura 17	Fluxograma do Processamento de Segmentação da Imagem	50
Figura 18	Atribuição das áreas de treino sobre a imagem segmentada	51
Figura 19	Fluxograma do processamento de classificação da imagem com o classificador <i>nearest neighbor</i> pelas áreas de treino definidas no <i>IDRISI Taiga</i>	53

Figura 20	Fluxograma do processamento da aplicação do algoritmo de majoração <i>SEGCLASS</i>	53
Figura 21	Fluxograma do processamento da classificação da imagem <i>pixel a pixel por Segmentos</i>	54
Figura 22	Fluxograma do processamento de segmentação da imagem	55
Figura 23	Fluxograma do processamento de classificação da imagem por níveis ...	56
Figura 24	Fluxograma relativo ao lançamento aleatório de pontos por classe	58
Figura 25	Fluxograma relativo à intersecção das unidades identificadas sobre as classificações	59
Figura 26	Resultado da classificação <i>pixel a pixel</i> , pelo algoritmo <i>random forests</i> ...	61
Figura 27	Amostra da imagem segmentada no <i>IDRISI Taiga</i>	62
Figura 28	Resultado intermédio da classificação <i>orientada por segmentos</i> , pelo algoritmo <i>nearest neighbor</i>	63
Figura 29	Resultado final da classificação <i>orientada por segmentos</i> , pelo algoritmo <i>nearest neighbor</i>	64
Figura 30	Resultado final da classificação combinada, <i>pixel a pixel</i> agrupada por <i>segmentos</i>	65
Figura 31	Amostra da imagem segmentada pelo algoritmo <i>multiresolution</i>	66
Figura 32	Resultado final da classificação <i>orientada por objectos</i> , <i>eCognition 8.0</i> , pela cor e textura (CT)	67
Figura 33	Resultado final da Classificação <i>Orientada por Objectos</i> , <i>eCognition 8.0</i> , pela Cor e Contexto (CC)	68
Figura 34	Amostra visual do processo de individualização dos segmentos	73
Figura 35	Amostra visual da sobreposição de dois resultados de segmentação	74
Figura 36	Amostra visual do processo de individualização dos objectos	76
Figura 37	Primeira amostra visual dos algoritmos de segmentação de cada <i>software</i> experimentado	77

Figura 38	Segunda amostra visual dos algoritmos de segmentação de cada <i>software</i> experimentado	77
Figura 39	Resultado da segmentação para ambos <i>softwares</i> na individualização dos carros	79
Figura 40	Resultado de um Ensaio de Classificação combinada, <i>pixel a pixel</i> agrupada por segmentos de <i>scale</i> igual a 10	87
Figura 41	Amostra visual da variabilidade espectral da classe ‘Edifícios com cobertura cerâmica’, em falsa cor	90
Figura 42	Amostra visual da classificação de um elemento urbano da classe ‘Edifícios de cobertura cerâmica’, pelos diferentes tipos de abordagem	91 e 92
Figura 43	Amostra visual de erros de classificação <i>orientada por objectos</i> da classe ‘Edifícios de cobertura cerâmica’	93
Figura 44	Amostra visual de elementos pertencentes à classe ‘Edifícios com cobertura cerâmica’ com similaridade de assinatura espectral, forma e textura a outras classes, em falsa cor	94 e 95
Figura 45	Amostra visual de elementos pertencentes à classe ‘Edifícios com cobertura de Betão’ com similaridade de assinatura espectral, forma e textura à classe ‘Pavimentos Betuminosos’, em falsa cor	96
Figura 46	Amostra visual da Classificação de um elemento urbano da classe ‘Edifícios com Cobertura de Betão’, pelos diferentes tipos de abordagem	97
Figura 47	Amostra visual de um elemento identificado como classe ‘Pavimentos betuminosos’, e resultados pelos diferentes tipos de abordagem	99
Figura 48	Amostra visual de elementos pertencentes à classe ‘Edifícios com cobertura metálica’ com similaridade de assinatura espectral, forma e textura a outras classes, em falsa cor	101
Figura 49	Amostra visual de um elemento identificado como classe ‘Pistas, Campos de Ténis e Ciclovias’, e resultados pelos diferentes tipos de abordagem	103
Figura 50	Amostra visual de um elemento pertencente à classe ‘Relvados Sintéticos e Campos de Jogos com pavimento de betão’ com similaridade de assinatura espectral à classe ‘Sombra’, em falsa cor	105

Figura 51	Segunda amostra visual de um elemento pertencente à classe ‘Relvados Sintéticos e Campos de Jogos com pavimento de betão’ com similitude de assinatura espectral, forma e textura com outras classes, em falsa cor ...	105
Figura 52	Amostra visual de dois elementos identificados como classe ‘Relvados Sintéticos e Campos de Jogos com pavimento de betão’, e resultados pelos diferentes tipos de abordagem	107
Figura 53	Amostra visual de um elemento pertencente à classe ‘Pavimentos Betuminosos’ com similitude de assinatura espectral à classe ‘Sombra’, em falsa cor	108
Figura 54	Amostra visual de um elemento pertencente à classe ‘Passeios e outras áreas pedonais’ com similitude de assinatura espectral a outras classes, em falsa cor	109
Figura 55	Amostra visual de elementos pertencente às classes de vegetação, em falsa cor	110
Figura 56	Amostra visual sobre os resultados de Classificação das classes de ‘Vegetação’ pelos diferentes tipos de abordagem	113
Figura 57	Resultado para a classificação <i>orientada por objectos</i> da imagem para a classe ‘Sombra’	115
Figura 58	Nomenclatura proposta para o ensaio	119
Figura 59	Segunda amostra visual da classificação de um elemento urbano da classe ‘Edifícios de cobertura cerâmica’, pelos diferentes tipos de abordagem	121
Figura 60	Amostra visual da segmentação executada para a classificação <i>orientada por segmentos e por objectos</i> , alusiva à classe ‘Edifícios com cobertura cerâmica’	122
Figura 61	Amostra visual da segmentação executada para diferentes valores de <i>scale</i> no <i>eCognition 8.0</i> , alusiva à classe ‘Edifícios com cobertura cerâmica’	123

LISTA DE TABELAS

Tabela 1	Simbologia esquematizada no processamento da Imagem	30
Tabela 2	Valores de covariância e correlação entre bandas	32
Tabela 3	Chave de Identificação das classes de nível 4, agrupadas em 3, por 'Edifícios'	37
Tabela 4	Chave de identificação das classes de nível 4, agrupadas em 3, por 'Infra-Estruturas Desportivas'	38
Tabela 5	Chave de identificação das classes de nível 4, agrupadas em 2, por 'Eixos de Circulação'	39
Tabela 6	Chave de identificação das classes de nível 4, agrupadas em 2, por 'Vegetação'	40
Tabela 7	Chave de identificação das classes de nível 4, agrupadas em 2, por 'Não Vegetação'	41
Tabela 8	Distribuição das áreas de treino por classe de nível 4	43
Tabela 9	Distribuição das áreas de treino por classe de nível 4	52
Tabela 10	Distribuição das áreas de treino por classe de nível 4	57
Tabela 11	Objectos Classificados por classe e por critério de identificação espacial	69
Tabela 12	Parâmetros manipulados no processamento de segmentação no <i>IDRISI Taiga</i>	72
Tabela 13	Exactidão global para todos os ensaios de classificação	80
Tabela 14	Valores para o Índice de concordância Kappa, para todos os ensaios de classificação	81
Tabela 15	Exactidão global e índice de concordância Kappa para o resultado intermédio da classificação <i>orientada por segmentos</i>	85
Tabela 16	Exactidão global e índice de concordância Kappa para a classificação <i>pixel a pixel</i> e para o resultado intermédio da classificação <i>orientada por segmentos</i>	86
Tabela 17	Exactidão do produtor e utilizador de cada classificação, para as classes do nível 4	89

Tabela 18	Intersecção das classes relativas à ‘Vegetação’, para cada abordagem ..	111
Tabela 19	Análise de exactidão para as classes do nível 3	116
Tabela 20	Análise de exactidão para as classes do nível 2	117
Tabela 21	Análise de exactidão para as classes do nível 1	118
Tabela 22	Exactidão global e índice de concordância Kappa para o resultado intermédio da classificação <i>orientada por segmentos</i>	120
Tabela 23	Matriz de confusão para o nível 4, discriminado por 13 classes.....	138
Tabela 24	Matriz de confusão para o nível 4, discriminado por 12 classes	139
Tabela 25	Matriz de confusão para o nível 3, discriminado por 9 classes	140
Tabela 26	Matriz de confusão para o nível 2, discriminado por 4 classes	141
Tabela 27	Matriz de confusão para o nível 1, discriminado por 2 classes	141
Tabela 28	Matriz de confusão para o nível 4, discriminado por 13 classes	142
Tabela 29	Matriz de confusão para o nível 4, discriminado por 12 classes	143
Tabela 30	Matriz de confusão para o nível 3, discriminado por 9 classes	144
Tabela 31	Matriz de confusão para o nível 2, discriminado por 4 classes	145
Tabela 32	Matriz de confusão para o nível 1, discriminado por 2 classes	145
Tabela 33	Matriz de confusão para o nível 4, discriminado por 13 classes	146
Tabela 34	Matriz de confusão para o nível 4, discriminado por 12 classes	147
Tabela 35	Matriz de confusão para o nível 3, discriminado por 9 classes	148
Tabela 36	Matriz de confusão para o nível 2, discriminado por 4 classes	149
Tabela 37	Matriz de confusão para o nível 1, discriminado por 2 classes	149
Tabela 38	Matriz de confusão para o nível 4, discriminado por 13 classes	150
Tabela 39	Matriz de confusão para o nível 4, discriminado por 12 classes	151
Tabela 40	Matriz de confusão para o nível 3, discriminado por 9 classes	152
Tabela 41	Matriz de confusão para o nível 2, discriminado por 4 classes	153
Tabela 42	Matriz de confusão para o nível 1, discriminado por 2 classes	153

GLOSSÁRIO

Arcgis	Software de Sistemas de Informação Geográfica
eCognition 8.0	Software de Processamento de Imagens de Satélite
ENVI 4.7.	Software de Processamento de Imagens de Satélite
Feature Analyst	Software de Extração de Elementos da imagem
Hawths Tools	Extensão para o software Arcgis para realizar análise espacial
IDRISI Taiga	Software de Processamento de Imagens de Satélite
IKONOS	Satélite de alta resolução espacial de observação terrestre
Quickbird	Satélite de alta resolução espacial de observação terrestre
R	Software de análise estatística
WORLDVIEW-2	Satélite de alta resolução espacial e espectral de observação terrestre

Anexo A: Matrizes de confusão para a Classificação *Pixel a Pixel*, para os diferentes níveis da nomenclatura

		Pixels Observados													Total	Erro de Comissão (%)	Exactidão do Produtor (%)
		Edifícios com cobertura cerâmica	Edifícios com cobertura de betão	Edifícios com cobertura Metálica	Pistas, Campos de Ténis, Ciclovias	Relvados Sintéticos e Campos de Jogos c/ pavimento de betão	Pavimentos betuminosos	Passeios e outras áreas pedonais	Vegetação Resinosa	Vegetação Folhosa	Vegetação Herbácea	Solo Exposto	Agua	Sombra			
Pixels Classificados	Edifícios com cobertura cerâmica	95	0	0	5	0	0	0	0	1	1	10	0	0	112	15	85
	Edifícios com cobertura de betão	29	50	0	0	0	75	33	0	5	3	14	0	8	217	77	23
	Edifícios com cobertura Metálica	0	6	80	0	0	0	7	0	0	0	0	0	0	93	14	86
	Pistas, Campos de Ténis, Ciclovias	14	0	0	21	0	0	0	0	0	0	1	0	0	36	42	58
	Relvados Sintéticos e Campos de Jogos com pavimento de betão	2	0	0	0	37	2	1	10	1	1	0	1	28	83	55	45
	Pavimentos betuminosos	2	11	1	0	1	67	0	1	0	0	0	3	26	112	40	60
	Passeios e outras áreas pedonais	8	31	10	0	0	9	39	0	0	0	20	0	0	117	67	33
	Veg. Resinosa	2		0	0	0	0	1	41	42	9	4	0	1	100	59	41
	Veg. Folhosa	0	0	0	0	0	0	0	2	38	15	0	0	0	55	31	69
	Veg. Herbácea	0	0	0	0	0	1	0	3	29	71	2	0	0	106	33	67
	Solo Exposto	15		0	6	0	0	3	5	12	21	73	0	0	135	46	54
	Agua	0	1	0	0	0	0	0	0	0	0	0	85	0	86	1	99
	Sombra	0	0	0	0	0	0	0	3	0	0	0	2	43	48	10	90
Total		167	99	91	32	38	154	84	65	128	121	124	91	106	1300		
Erro de Omissão (%)		43	49	12	34	3	56	54	37	70	41	41	7	59			
Exactidão do Utilizador (%)		57	51	88	66	97	44	46	63	30	59	59	93	41			

Tabela 23 – Matriz de confusão para o nível 4, discriminado por 13 classes

		Pixels Observados														
		Edifícios com cobertura cerâmica	Edifícios com cobertura de betão	Edifícios com cobertura Metálica	Pistas, Campos de Tênis, Ciclovias	Relvados Sintéticos e Campos de Jogos c/ pavimento de betão	Pavimentos betuminosos	Passeios e outras áreas pedonais	Vegetação Arbórea	Vegetação Herbácea	Solo Exposto	Água	Sombra	Total	Erro de Comissão (%)	Exactidão do Produtor (%)
Pixels Classificados	Edifícios com cobertura cerâmica	95	0	0	5	0	0	0	1	1	10	0	0	112	15	85
	Edifícios com cobertura de betão	29	50	0	0	0	75	33	5	3	14	0	8	217	77	23
	Edifícios com cobertura Metálica	0	6	80	0	0	0	7	0	0	0	0	0	93	14	86
	Pistas, Campos de Tênis, Ciclovias	14	0	0	21	0	0	0	0	0	1	0	0	36	42	58
	Relvados Sintéticos e Campos de Jogos com pavimento de betão	2	0	0	0	37	2	1	11	1	0	1	28	83	55	45
	Pavimentos betuminosos	2	11	1	0	1	67	0	1	0	0	3	26	112	40	60
	Passeios e outras áreas pedonais	8	31	10	0	0	9	39	0	0	20	0	0	117	67	33
	Veg. Arbórea	2	0	0	0	0	0	1	123	24	4	0	1	155	21	79
	Veg. Herbácea		0	0	0	0	1		32	71	2	0	0	106	33	67
	Solo Exposto	15	0	0	6	0	0	3	17	21	73	0	0	135	46	54
	Água	0	1	0		0	0	0	0	0	0	85	0	86	1	99
	Sombra	0	0	0	0	0	0	0	3	0	0	2	43	48	10	90
	Total	167	99	91	32	38	154	84	193	121	124	91	106	1300		
Erro de Omissão (%)		43	49	12	34	3	56	54	36	41	41	7	59			
Exactidão do Utilizador (%)		57	51	88	66	97	44	46	64	59	59	93	41			

Tabela 24 – Matriz de confusão para o nível 4, discriminado por 12 classes

		Pixels Observados									Total	Erro de Comissão (%)	Exactidão do Produtor (%)
		Edifícios	Infra-Estruturas Desportivas	Pavimentos betuminosos	Passeios e outras áreas pedonais	Vegetação Arbórea	Vegetação Herbácea	Solo Exposto	Água	Sombra			
Pixels Classificados	Edifícios	260	5	75	40	6	4	24	0	8	422	38	62
	Infra-Estruturas Desportivas	16	58	2	1	11	1	1	1	28	119	51	49
	Pavimentos betuminosos	14	1	67	0	1	0	0	3	26	112	40	60
	Passeios e outras áreas pedonais	49	0	9	39	0	0	20	0	0	117	67	33
	Veg. Arbórea	2	0	0	1	123	24	4	0	1	155	21	79
	Veg. Herbácea	0	0	1	0	32	71	2	0	0	106	33	67
	Solo Exposto	15	6	0	3	17	21	73	0	0	135	46	54
	Água	1	0	0	0	0	0	0	85	0	86	1	99
	Sombra	0	0	0	0	3	0	0	2	43	48	10	90
Total		357	70	154	84	193	121	124	91	106	1300		
Erro de Omissão (%)		27	17	56	54	36	41	41	7	59			
Exactidão do Utilizador (%)		73	83	44	46	64	59	59	93	41			

Tabela 25 – Matriz de confusão para o nível 3, discriminado por 9 classes

		Pixels Observados				Total	Erro de Comissão (%)	Exactidão do Produtor (%)
		Edifícios	Pavimentos betuminosos	Vegetação	Solo Exposto			
Pixels Classificados	Edifícios e Infra-Estruturas Desportivas	339	118	22	62	541	37	63
	Eixos de Circulação	64	115	1	49	229	50	50
	Vegetação	2	2	250	7	261	4	96
	Não vegetação	22	3	41	203	269	25	75
	Total	427	238	314	321	1300		
	Erro de Omissão (%)	21	52	20	37			
	Exactidão do Utilizador (%)	79	48	80	63			

Tabela 26 – Matriz de confusão para o nível 2, discriminado por 4 classes

		Pixels Observados		Total	Erro de Comissão (%)	Exactidão do Produtor (%)
		Urbano	Não Urbano			
Pixels Classificados	Urbano	636	134	770	17	83
	Não Urbano	29	501	530	5	95
	Total	665	635	1300		
	Erro de Omissão (%)	4	21			
	Exactidão do Utilizador (%)	96	79			

Tabela 27 – Matriz de confusão para o nível 1, discriminado por 2 classes

Anexo B: Matrizes de confusão para a Classificação *orientada por segmentos*, pelo *IDRISI Taiga*, para os diferentes níveis da nomenclatura

		Pixels Observados													Total	Erro de Comissão (%)	Exactidão do Produtor (%)
		Edifícios com cobertura cerâmica	Edifícios com cobertura de betão	Edifícios com cobertura Metálica	Pistas, Campos de Ténis, Cicloviás	Relvados Sintéticos e Campos de Jogos c/ pavimento de betão	Pavimentos betuminosos	Passeios e outras áreas pedonais	Vegetação Resinosa	Vegetação Folhosa	Vegetação Herbácea	Solo Exposto	Água	Sombra			
Pixels Classificados	Edifícios com cobertura cerâmica	100	0	1	3	0	2	8	0	2	0	8	0	1	125	20	80
	Edifícios com cobertura de betão	31	52	5	1	0	65	26	1	10	10	12	0	10	223	77	23
	Edifícios com cobertura Metálica	0	7	73		0	1	2	0	0	0	0	0	1	84	13	87
	Pistas, Campos de Ténis, Cicloviás	7	0	0	19	0	0	1	0	0	1	0	0	0	28	32	68
	Relvados Sintéticos e Campos de Jogos com pavimento de betão	5	3	0	0	36	0	1	6		0	1		17	69	48	52
	Pavimentos betuminosos	3	6	1	0	2	73	3	0	3	0	1	3	19	114	36	64
	Passeios e outras áreas pedonais	5	27	10	0	0	5	34	0	2	0	23		1	107	68	32
	Veg. Resinosa	1	0	0	0	0	1	3	45	44	7	3	1	1	106	58	42
	Veg. Folhosa	1	0	0	0	0	1		2	42	14	0	0		60	30	70
	Veg. Herbácea	1	0	0	0	0	1	5	3	14	78	3	0	5	110	29	71
	Solo Exposto	11	0	1	9	0	3	1	3	10	10	73	0	4	125	42	58
	Água	0	2	0	0	0	0	0	5	1	1		87		96	9	91
	Sombra	2	2	0	0	0	2	0	0	0	0	0	0	47	53	11	89
	Total	167	99	91	32	38	154	84	65	128	121	124	91	106	1300		
Erro de Omissão (%)		40	47	20	41	5	53	60	31	67	36	41	4	56			
Exactidão do Utilizador (%)		60	53	80	59	95	47	40	69	33	64	59	96	44			

Tabela 28 – Matriz de confusão para o nível 4, discriminado por 13 classes

		Pixels Observados														
		Edifícios com cobertura cerâmica	Edifícios com cobertura de betão	Edifícios com cobertura Metálica	Pistas, Campos de Tênis, Ciclovias	Relvados Sintéticos e Campos de Jogos c/ pavimento de betão	Pavimentos betuminosos	Passeios e outras áreas pedonais	Vegetação Arbórea	Vegetação Herbácea	Solo Exposto	Agua	Sombra	Total	Erro de Comissão (%)	Exactidão do Produtor (%)
Pixels Classificados	Edifícios com cobertura cerâmica	100	0	1	3	0	2	8	2	0	8	0	1	125	20	80
	Edifícios com cobertura de betão	31	52	5	1	0	65	26	11	10	12	0	10	223	77	23
	Edifícios com cobertura Metálica	0	7	73		0	1	2	0	0	0	0	1	84	13	87
	Pistas, Campos de Tênis, Ciclovias	7	0	0	19	0	0	1	0	1	0	0		28	32	68
	Relvados Sintéticos e Campos de Jogos com pavimento de betão	5	3	0	0	36	0	1	6	0	1	0	17	69	48	52
	Pavimentos betuminosos	3	6	1	0	2	73	3	3	0	1	3	19	114	36	64
	Passeios e outras áreas pedonais	5	27	10	0	0	5	34	2	0	23		1	107	68	32
	Veg. Arbórea	2	0	0	0	0	2	3	133	21	3	1	1	166	20	80
	Veg. Herbácea	1	0	0	0	0	1	5	17	78	3	0	5	110	29	71
	Solo Exposto	11	0	1	9	0	3	1	13	10	73	0	4	125	42	58
	Agua	0	2	0	0	0	0	0	6	1	0	87	0	96	9	91
	Sombra	2	2	0	0	0	2	0	0	0	0	0	47	53	11	89
	Total	167	99	91	32	38	154	84	193	121	124	91	106	1300		
Erro de Omissão (%)		40	47	20	41	5	53	60	31	36	41	4	56			
Exactidão do Utilizador (%)		60	53	80	59	95	47	40	69	64	59	96	44			

Tabela 29 – Matriz de confusão para o nível 4, discriminado por 12 classes

		Pixels Observados									Total	Erro de Comissão (%)	Exactidão do Produtor (%)
		Edifícios	Infra-Estruturas Desportivas	Pavimentos betuminosos	Passeios e outras áreas pedonais	Vegetação Arbórea	Vegetação Herbácea	Solo Exposto	Água	Sombra			
Pixels Classificados	Edifícios	269	4	68	36	13	10	20		12	432	38	62
	Infra-Estruturas Desportivas	15	55		2	6	1	1		17	97	43	57
	Pavimentos betuminosos	10	2	73	3	3		1	3	19	114	36	64
	Passeios e outras áreas pedonais	42		5	34	2		23		1	107	68	32
	Veg. Arbórea	2		2	3	133	21	3	1	1	166	20	80
	Veg. Herbácea	1		1	5	17	78	3		5	110	29	71
	Solo Exposto	12	9	3	1	13	10	73		4	125	42	58
	Água	2				6	1		87		96	9	91
	Sombra	4		2						47	53	11	89
Total		357	70	154	84	193	121	124	91	106	1300		
Erro de Omissão (%)		25	21	53	60	31	36	41	4	56			
Exactidão do Utilizador (%)		75	79	47	40	69	64	59	96	44			

Tabela 30 – Matriz de confusão para o nível 3, discriminado por 9 classes

		Pixels Observados				Total	Erro de Comissão (%)	Exactidão do Produtor (%)
		Edifícios	Pavimentos betuminosos	Vegetação	Solo Exposto			
Pixels Classificados	Edifícios e Infra-Estruturas Desportivas	343	106	30	50	529	35	65
	Eixos de Circulação	54	115	5	47	221	48	52
	Vegetação	3	11	249	13	276	10	90
	Não vegetação	27	6	30	211	274	23	77
	Total	427	238	314	321	1300		
	Erro de Omissão (%)	20	52	21	34			
	Exactidão do Utilizador (%)	80	48	79	66			

Tabela 31 – Matriz de confusão para o nível 2, discriminado por 4 classes

		Pixels Observados		Total	Erro de Comissão (%)	Exactidão do Produtor (%)
		Urbano	Não Urbano			
Pixels Classificados	Urbano	618	132	750	18	82
	Não Urbano	47	503	550	9	91
	Total	665	635	1300		
	Erro de Omissão (%)	7	21			
		Exactidão do Utilizador (%)	93	79		

Tabela 32 – Matriz de confusão para o nível 1, discriminado por 2 classes

Anexo C: Matrizes de confusão para a Classificação Combinada, *Pixel a Pixel*, agrupada por Segmentos, para os diferentes níveis da nomenclatura

		Pixels Observados															
		Edifícios com cobertura cerâmica	Edifícios com cobertura de betão	Edifícios com cobertura Metálica	Pistas, Campos de Ténis, Cicloviás	Relvados Sintéticos e Campos de Jogos c/ pavimento de betão	Pavimentos betuminosos	Passeios e outras áreas pedonais	Vegetação Resinosa	Vegetação Folhosa	Vegetação Herbácea	Solo Exposto	Agua	Sombra	Total	Erro de Comissão (%)	Exactidão do Produtor (%)
Pixel/s Classificados	Edifícios com cobertura cerâmica	100	0	1	3	0	2	8	0	2	0	8	0	1	125	20	80
	Edifícios com cobertura de betão	31	52	5	1	0	65	26	1	10	10	12	0	10	223	77	23
	Edifícios com cobertura Metálica	0	7	73		0	1	2	0	0	0	0	0	1	84	13	87
	Pistas, Campos de Ténis, Cicloviás	7	0	0	19	0	0	1	0	0	1	0	0	0	28	32	68
	Relvados Sintéticos e Campos de Jogos com pavimento de betão	5	3	0	0	36	0	1	6	0	0	1	0	17	69	48	52
	Pavimentos betuminosos	3	6	1	0	2	73	3	0	3	0	1	3	19	114	36	64
	Passeios e outras áreas pedonais	5	27	10	0	0	5	34	0	2	0	23		1	107	68	32
	Veg. Resinosa	1	0	0	0	0	1	3	45	44	7	3	1	1	106	58	42
	Veg. Folhosa	1	0	0	0	0	1		2	42	14	0	0	0	60	30	70
	Veg. Herbácea	1	0	0	0	0	1	5	3	14	78	3	0	5	110	29	71
	Solo Exposto	11	0	1	9	0	3	1	3	10	10	73	0	4	125	42	58
	Agua	0	2	0	0	0	0	0	5	1	1	0	87	0	96	9	91
	Sombra	2	2	0	0	0	2	0	0	0	0	0	0	47	53	11	89
Total		167	99	91	32	38	154	84	65	128	121	124	91	106	1300		
Erro de Omissão (%)		40	47	20	41	5	53	60	31	67	36	41	4	56			
Exactidão do Utilizador (%)		60	53	80	59	95	47	40	69	33	64	59	96	44			

Tabela 33 – Matriz de confusão para o nível 4, discriminado por 13 classes

		Pixels Observados														
		Edifícios com cobertura cerâmica	Edifícios com cobertura de betão	Edifícios com cobertura Metálica	Pistas, Campos de Tênis, Ciclovias	Relvados Sintéticos e Campos de Jogos c/ pavimento de betão	Pavimentos betuminosos	Passeios e outras áreas pedonais	Vegetação Arbórea	Vegetação Herbácea	Solo Exposto	Agua	Sombra	Total	Erro de Comissão (%)	Exactidão do Produtor (%)
Pixels Classificados	Edifícios com cobertura cerâmica	100	0	1	3	0	2	8	2	0	8	0	1	125	20	80
	Edifícios com cobertura de betão	31	52	5	1	0	65	26	11	10	12	0	10	223	77	23
	Edifícios com cobertura Metálica	0	7	73		0	1	2	0	0	0	0	1	84	13	87
	Pistas, Campos de Tênis, Ciclovias	7		0	19	0	0	1	0	1	0	0	0	28	32	68
	Relvados Sintéticos e Campos de Jogos com pavimento de betão	5	3	0	0	36	0	1	6	0	1	0	17	69	48	52
	Pavimentos betuminosos	3	6	1	0	2	73	3	3	0	1	3	19	114	36	64
	Passeios e outras áreas pedonais	5	27	10	0	0	5	34	2	0	23	0	1	107	68	32
	Veg. Arbórea	2	0	0	0	0	2	3	133	21	3	1	1	166	20	80
	Veg. Herbácea	1	0	0	0	0	1	5	17	78	3	0	5	110	29	71
	Solo Exposto	11	0	1	9	0	3	1	13	10	73	0	4	125	42	58
	Agua	0	2	0	0	0	0	0	6	1	0	87	0	96	9	91
	Sombra	2	2	0	0	0	2	0	0	0	0	0	47	53	11	89
	Total	167	99	91	32	38	154	84	193	121	124	91	106	1300		
Erro de Omissão (%)		40	47	20	41	5	53	60	31	36	41	4	56			
Exactidão do Utilizador (%)		60	53	80	59	95	47	40	69	64	59	96	44			

Tabela 34 – Matriz de confusão para o nível 4, discriminado por 12 classes

		Pixels Observados									Total	Erro de Comissão (%)	Exactidão do Produtor (%)
		Edifícios	Infra-Estruturas Desportivas	Pavimentos betuminosos	Passeios e outras áreas pedonais	Vegetação Arbórea	Vegetação Herbácea	Solo Exposto	Água	Sombra			
Pixels Classificados	Edifícios	269	4	68	36	13	10	20	0	12	432	38	62
	Infra-Estruturas Desportivas	15	55		2	6	1	1	0	17	97	43	57
	Pavimentos betuminosos	10	2	73	3	3	0	1	3	19	114	36	64
	Passeios e outras áreas pedonais	42	0	5	34	2	0	23	0	1	107	68	32
	Veg. Arbórea	2	0	2	3	133	21	3	1	1	166	20	80
	Veg. Herbácea	1	0	1	5	17	78	3	0	5	110	29	71
	Solo Exposto	12	9	3	1	13	10	73	0	4	125	42	58
	Água	2	0	0	0	6	1		87	0	96	9	91
	Sombra	4	0	2	0	0	0	0	0	47	53	11	89
Total		357	70	154	84	193	121	124	91	106	1300		
Erro de Omissão (%)		25	21	53	60	31	36	41	4	56			
Exactidão do Utilizador (%)		75	79	47	40	69	64	59	96	44			

Tabela 35 – Matriz de confusão para o nível 3, discriminado por 9 classes

		Pixels Observados				Total	Erro de Comissão (%)	Exactidão do Produtor (%)
		Edifícios	Pavimentos betuminosos	Vegetação	Solo Exposto			
Pixels Classificados	Edifícios e Infra-Estruturas Desportivas	343	106	30	50	529	35	65
	Eixos de Circulação	54	115	5	47	221	48	52
	Vegetação	3	11	249	13	276	10	90
	Não vegetação	27	6	30	211	274	23	77
	Total	427	238	314	321	1300		
	Erro de Omissão (%)	20	52	21	34			
	Exactidão do Utilizador (%)	80	48	79	66			

Tabela 36 – Matriz de confusão para o nível 2, discriminado por 4 classes

		Pixels Observados		Total	Erro de Comissão (%)	Exactidão do Produtor (%)
		Urbano	Não Urbano			
Pixels Classificados	Urbano	618	132	750	18	82
	Não Urbano	47	503	550	9	91
	Total	665	635	1300		
		Erro de Omissão (%)				
		7	21			
		Exactidão do Utilizador (%)				
		93	79			

Tabela 37 – Matriz de confusão para o nível 1, discriminado por 2 classes

Anexo D: Matrizes de confusão para a Classificação orientada por objectos, pelo *eCognition 8.0*, para os diferentes níveis da nomenclatura

		Pixels Observados													Total	Erro de Comissão (%)	Exactidão do Produtor (%)
		Edifícios com cobertura cerâmica	Edifícios com cobertura de betão	Edifícios com cobertura Metálica	Pistas, Campos de Ténis, Cicloviás	Relvados Sintéticos e Campos de Jogos c/ pavimento de betão	Pavimentos betuminosos	Passeios e outras áreas pedonais	Vegetação Resinosa	Vegetação Folhosa	Vegetação Herbácea	Solo Exposto	Agua	Sombra			
Pixels Classificados	Edifícios com cobertura cerâmica	103	1	0	0	0	9	10	0	1	3	13	0	1	141	27	73
	Edifícios com cobertura de betão	19	51	0	0	0	58	12	0	2	2	12	0	1	157	68	32
	Edifícios com cobertura Metálica	1	8	74	0	0	0	5	0	0	0	2	0	0	90	18	82
	Pistas, Campos de Ténis, Cicloviás	21	0	0	30	0	0	0	0	0	0	5	0	0	56	46	54
	Relvados Sintéticos e Campos de Jogos com pavimento de betão	0	7	0	0	36	3	3	1	0	0	10	0	0	60	40	60
	Pavimentos betuminosos	2	4	1	0	2	62	0	2	2	2	3	3	4	87	29	71
	Passeios e outras áreas pedonais	11	20	16	1	0	12	49	1	6	1	8	0	2	127	61	39
	Veg. Resinosa	1	3	0	0	0	1	0	52	34	9	4	0	9	113	54	46
	Veg. Folhosa	0	0	0	0	0	0	0	3	63	18		0		84	25	75
	Veg. Herbácea	0	0	0	0	0	2	0	1	12	76	8	0	1	100	24	76
	Solo Exposto	7	0	0	1	0	2	1	3	5	9	59	0		87	32	68
	Agua	0	1	0	0	0	0	0	0	0	0	0	88	4	93	5	95
	Sombra	2	4	0	0	0	5	4	2	3	1	0	0	84	105	20	80
	Total	167	99	91	32	38	154	84	65	128	121	124	91	106	1300		
Erro de Omissão (%)		38	48	19	6	5	60	42	20	51	37	52	3	21			
Exactidão do Utilizador (%)		62	52	81	94	95	40	58	80	49	63	48	97	79			

Tabela 38 – Matriz de confusão para o nível 4, discriminado por 13 classes

		Pixels Observados														
		Edifícios com cobertura cerâmica	Edifícios com cobertura de betão	Edifícios com cobertura Metálica	Pistas, Campos de Ténis, Ciclovias	Relvados Sintéticos e Campos de Jogos c/ pavimento de betão	Pavimentos betuminosos	Passeios e outras áreas pedonais	Vegetação Arbórea	Vegetação Herbácea	Solo Exposto	Agua	Sombra	Total	Erro de Comissão (%)	Exactidão do Operador (%)
Pixels Classificados	Edifícios com cobertura cerâmica	103	1	0	0	0	9	10	1	3	13	0	1	141	27	73
	Edifícios com cobertura de betão	19	51	0	0	0	58	12	2	2	12	0	1	157	68	32
	Edifícios com cobertura Metálica	1	8	74	0	0	0	5	0	0	2	0	0	90	18	82
	Pistas, Campos de Ténis, Ciclovias	21		0	30	0	0	0	0	0	5	0	0	56	46	54
	Relvados Sintéticos e Campos de Jogos com pavimento de betão	0	7	0	0	36	3	3	1	0	10	0	0	60	40	60
	Pavimentos betuminosos	2	4	1	0	2	62		4	2	3	3	4	87	29	71
	Passeios e outras áreas pedonais	11	20	16	1	0	12	49	7	1	8		2	127	61	39
	Veg. Arbórea	1	3	0	0	0	1	0	152	27	4	0	9	197	23	77
	Veg. Herbácea	0	0	0	0	0	2	0	13	76	8	0	1	100	24	76
	Solo Exposto	7	0	0	1	0	2	1	8	9	59	0		87	32	68
	Agua	0	1	0	0	0	0	0	0	0	0	88	4	93	5	95
	Sombra	2	4	0	0	0	5	4	5	1	0		84	105	20	80
	Total	167	99	91	32	38	154	84	193	121	124	91	106	1300		
Erro de Omissão (%)		38	48	19	6	5	60	42	21	37	52	3	21			
Exactidão do Utilizador (%)		62	52	81	94	95	40	58	79	63	48	97	79			

Tabela 39 – Matriz de confusão para o nível 4, discriminado por 12 classes

		Pixels Observados									Total	Erro de Comissão (%)	Exactidão do Operador (%)
		Edifícios	Infra-Estruturas Desportivas	Pavimentos betuminosos	Passeios e outras áreas pedonais	Vegetação Resinosa	Vegetação Herbácea	Solo Exposto	Agua	Sombra			
Pixels Classificados	Edifícios	257	0	67	27	3	5	27	0	2	388	34	66
	Infra-Estruturas Desportivas	28	66	3	3	1	0	15	0	0	116	43	57
	Pavimentos betuminosos	7	2	62	0	4	2	3	3	4	87	29	71
	Passeios e outras áreas pedonais	47	1	12	49	7	1	8	0	2	127	61	39
	Veg. Resinosa	4	0	1	0	152	27	4	0	9	197	23	77
	Veg. Herbácea	0	0	2	0	13	76	8	0	1	100	24	76
	Solo Exposto	7	1	2	1	8	9	59	0	0	87	32	68
	Agua	1	0	0	0	0	0	0	88	4	93	5	95
	Sombra	6	0	5	4	5	1	0	0	84	105	20	80
Total		357	70	154	84	193	121	124	91	106	1300		
Erro de Omissão (%)		28	6	60	42	21	37	52	3	21			
Exactidão do Utilizador (%)		72	94	40	58	79	63	48	97	79			

Tabela 40 – Matriz de confusão para o nível 3, discriminado por 9 classes

		Pixels Observados				Total	Erro de Comissão (%)	Exactidão do Operador (%)
		Edifícios	Pavimentos betuminosos	Vegetação	Solo Exposto			
Pixels Classificados	Edifícios e Infra-Estruturas Desportivas	351	100	9	44	504	30	70
	Eixos de Circulação	57	123	14	20	214	43	57
	Vegetação	4	3	268	22	297	10	90
	Não vegetação	15	12	23	235	285	18	82
	Total	427	238	314	321	1300		
	Erro de Omissão (%)	18	48	15	27			
	Exactidão do Utilizador (%)	82	52	85	73			

Tabela 41 – Matriz de confusão para o nível 2, discriminado por 4 classes

		Pixels Observados		Total	Erro de Comissão (%)	Exactidão do Operador (%)
		Urbano	Não Urbano			
Pixels Classificados	Urbano	631	87	718	12	88
	Não Urbano	34	548	582	6	94
	Total	665	635	1300		
	Erro de Omissão (%)	5	14			
	Exactidão do Utilizador (%)	95	86			

Tabela 42 – Matriz de confusão para o nível 1, discriminado por 2 classes