

**DETECÇÃO REMOTA EM MEIO URBANO:
TESTE COM CLASSIFICADORES SUPERVISIONADOS A NÍVEL DO PIXEL SOBRE
IMAGENS DE ALTA RESOLUÇÃO ESPACIAL APLICADOS NUMA LÓGICA
HIERÁRQUICA DE CLASSES**

Paulo Jorge Borges Martins Crisógono

**Dissertação de Mestrado em Gestão do Território, Especialização
em Detecção Remota**

Março 2011

Dissertação de Mestrado em Gestão do Território, Área de Especialização em Detecção Remota e Sistemas de Informação Geográfica, elaborada no âmbito do projecto GeoSat – Metodologias para extracção de informação GEOgráfica a grande escala a partir de imagens de SATélite de alta resolução (PTDC/GEO/64826/2006), financiado pela Fundação para a Ciência e a Tecnologia e desenvolvido no e-GEO – Centro de Estudos de Geografia e Planeamento Regional da Faculdade de Ciências Sociais e Humanas da Universidade Nova de Lisboa.



AGRADECIMENTOS

O processo evolutivo de uma tese desde a concepção da ideia à última linha tem uma vida turbulenta. De facto, o entusiasmo com o qual se acompanha as primeiras linhas vai sendo posto à prova à medida que o trabalho decorre. É sem dúvida uma prova de resistência em todo o esplendor, onde o Norte nunca pode deixar de ser vislumbrado, mesmo que muitas vezes tenhamos que caminhar de olhos fechados na incerteza do caminho. Contudo, esta prova nunca foi uma caminhada solitária. Foi sempre acompanhada por pessoas que souberam sempre fazer-se presentes, com a sua palavra, com o seu conhecimento, com os conselhos e a quem quero prestar a minha homenagem e dirigir o meu agradecimento sincero.

Quero aqui deixar o meu profundo agradecimento ao Professor Doutor José António Tenedório, por ter aceite a orientação desta tese, e pelo apoio ao longo do seu desenvolvimento, e acima de tudo pelo estímulo intelectual das nossas conversas. Um agradecimento também ao Mestre Sérgio Freire, pela sempre atenta observação e crítica, e pela motivação constante.

Agradeço aos meus pais pela educação que me deram, pelos valores, orientações e oportunidades, sem as quais seria com certeza humanamente mais pobre. Aos Amigos, pelo apoio e exemplo que me dão e continuam a dar e que de tanto me valem.

Em último lugar um sentido agradecimento à minha esposa Sónia, sem a qual esta tarefa teria um peso indubitavelmente maior. Agradeço a sua constante solicitude, nos conselhos, na crítica, e na correcção do texto. Mas acima de tudo pela sua presença, pela sua motivação e pelo seu sorriso. Também deixo um pequeno grande obrigado à minha filha Madalena, com a qual posso parar e reaprender a beleza das coisas.

RESUMO

DETECÇÃO REMOTA EM MEIO URBANO: TESTE COM CLASSIFICADORES SUPERVISIONADOS A NÍVEL DO PIXEL SOBRE IMAGENS DE ALTA RESOLUÇÃO ESPACIAL APLICADOS NUMA LÓGICA HIERÁRQUICA DE CLASSES

PAULO JORGE BORGES MARTINS CRISÓGONO

PALAVRAS-CHAVE: Detecção Remota, Imagens de Satélite, Resolução Espacial, Exactidão temática, Classificadores Supervisionados, Uso do Solo.

As constantes alterações no uso e ocupação do solo nos centros urbanos requerem informação geográfica actualizada e precisa, de uma forma cada vez mais célere, tornando requisito essencial para uma melhor gestão do meio urbano a produção de cartografia digital expedita e a escalas compatíveis com as exigências das autarquias.

A relação complexa e heterogénea entre os elementos que compõem o meio urbano e que apresentam, em imagens de satélite, um enorme leque de respostas espectrais, com diversas formas e texturas, resultam em padrões complexos e de difícil exploração, tornando a sua classificação uma tarefa difícil.

O advento das imagens de satélite de alta resolução espacial abriu uma nova janela no uso e exploração deste tipo de imagens, tornando possível estudar métodos de classificação novos ou já existentes analisando a riqueza espacial e a variabilidade espectral destas imagens.

Recorrendo a uma imagem de alta resolução espacial proveniente do satélite QuickBird para os testes realizados, esta tese pretende contribuir para o desenvolvimento de processos de classificação de meio urbano mais eficazes e que conduzam a uma maior exactidão nos resultados, propondo dois processos de classificação, numa análise estratificada por níveis temáticos com base numa hierarquia de classes pré-estabelecida.

A utilização de classificadores *pixel a pixel* pretendeu mitigar limitações na utilização de classificadores deste tipo em imagens de alta resolução espacial. De entre os classificadores *pixel a pixel*, utilizámos unicamente os supervisionados, baseados na selecção de parcelas de treino espectralmente representativas das classes que se desejava classificar.

ABSTRACT

REMOTE SENSING IN URBAN LANDSCAPE:

A TEST WITH SUPERVISED CLASSIFIERS AT PIXEL LEVEL IN HIGH SPATIAL RESOLUTION IMAGES APPLIED IN A HIERARCHICAL LOGIC OF CLASSES

PAULO JORGE BORGES MARTINS CRISÓGONO

KEYWORDS: Remote Sensing, Satellite Images, Spatial Resolution, Spatial Resolution, Thematic Accuracy, Supervised Classifiers, Land Use.

The constant changes in urban land cover and land use require timely and accurate geographic information with an increasingly higher urgency, making the expedite production of digital maps at scales compatible with the requirements of municipalities a key element for better management of urban areas.

The complex and heterogeneous relationship between the elements in urban areas represent, in satellite images, an increased difficulty because of the enormous range of spectral responses with various shapes and textures resulting in complex patterns which make accurate classification a difficult task.

The advent of satellite imagery of high spatial resolution represented a new opportunity in the use and exploration of such images, making it possible to study new and previously existing methods of classification, and analyzing the spatial variability and spectral richness of these images.

Using a high spatial resolution image from the QuickBird satellite, this thesis aims to contribute to the development of more effective classification processes and lead to greater accuracy in results, proposing two classification methods, in a stratified analysis by thematic levels based on a pre-established hierarchy of classes.

The use of *pixel to pixel* classifiers intended to mitigate limitations in the use of these types of classifiers in such high spatial resolution images. Among *pixel to pixel* classifiers, we used only supervised ones, for they allow the selection of training areas spectrally representative of the classes to sort.

ÍNDICE

INTRODUÇÃO	1
CAPÍTULO I: OBJECTO E METODOLOGIA	5
CAPÍTULO II: NOMENCLATURAS E METODOLOGIAS DE CLASSIFICAÇÕES DE USO DO SOLO URBANO EM IMAGENS DE SATÉLITE: UM ESTADO DA ARTE	7
II.1 CORPUS BIBLIOGRÁFICO DE REFERÊNCIA	7
II.2 NOMENCLATURAS URBANAS	9
II.3 CLASSIFICADORES <i>PIXEL A PIXEL</i>	29
II.3.1 Classificadores não-supervisionados	29
II.3.2 Classificadores supervisionados.....	30
II.4 FERRAMENTAS DE AVALIAÇÃO DE EXACTIDÃO DE RESULTADOS.....	41
II.4.1 Matriz de confusão	41
II.4.2 Índice de concordância Kappa	42
CAPÍTULO III: EXPERIMENTAÇÃO DE CLASSIFICADORES SOBRE IMAGENS QUICKBIRD	45
III.1 DADOS E ÁREA DE ESTUDO	45
III.2 METODOLOGIA	45
III.2.1 NOMENCLATURA PROPOSTA.....	45
III.2.2 PROCESSOS DE CLASSIFICAÇÃO PROPOSTOS	47
CAPÍTULO IV: RESULTADOS E DISCUSSÃO	55
IV.1 PROCESSO DE CLASSIFICAÇÃO POR NÍVEIS.....	55
IV.2 PROCESSO DE CLASSIFICAÇÃO POR CLASSES	59
IV.3 PROCESSO DE CLASSIFICAÇÃO POR NÍVEIS VS PROCESSO DE CLASSIFICAÇÃO POR CLASSES	63
IV.4 PROCESSOS DE CLASSIFICAÇÃO PROPOSTOS VS CLASSIFICAÇÃO DIRECTA DAS CLASSES MAIS DISCRIMINANTES	70
CAPÍTULO V: CONCLUSÕES	75
BIBLIOGRAFIA DE REFERÊNCIA	78
BIBLIOGRAFIA GERAL E FONTES	79
LISTA DE FIGURAS	82
LISTA DE TABELAS	85
GLOSSÁRIO	88

ANEXO 1: CÁLCULOS AUXILIARES PARA UMA MATRIZ DE CONFUSÃO	89
ANEXO 2: DEFINIÇÃO DE “OU EXCLUSIVO”	90
ANEXO 3: EXACTIDÕES DAS MELHORES CLASSIFICAÇÕES DO PCN	91
ANEXO 4: MAPAS DE REFERÊNCIA PARA OS VÁRIOS NÍVEIS TEMÁTICOS	94
ANEXO 5: MAPAS DAS MELHORES CLASSIFICAÇÕES NO PROCESSO DE CLASSIFICAÇÃO POR NÍVEIS	98
ANEXO 6: MAPAS DAS MELHORES CLASSIFICAÇÕES NO PROCESSO DE CLASSIFICAÇÃO POR CLASSES	102
ANEXO 7: MAPA DA NOMENCLATURA FINAL NO PROCESSO DE CLASSIFICAÇÃO POR NÍVEIS .	106
ANEXO 8: MAPA DA NOMENCLATURA FINAL NO PROCESSO DE CLASSIFICAÇÃO POR CLASSES	107

LISTA DE ABREVIATURAS E ACRÓNIMOS

IFOV	Campo instantâneo de visão
SIG	Sistema de Informação Geográfica
LIDAR	LIght Detection And Ranging
NDVI	Normalized Difference Vegetation Index
PIXEL	Picture Element
EG	Exactidão Global
EU	Exactidão do Utilizador
MV	Máxima Verosimilhança
MD	Mínima Distância
MAHA	Mahalanobis
PARA	Paralelepípedo
PCN	Processo de Classificação por Níveis
PCC	Processo de Classificação por Classes
CDCD	Classificação Directa das Classes mais Discriminates

Introdução

As alterações ao uso e ocupação do solo nos centros urbanos são hoje constantes, de forma que a produção de cartografia adequada que ajude os decisores na tomada de decisão não as acompanha.

Com efeito, o desenvolvimento dos centros urbanos, em particular das grandes cidades, no planeamento de grandes infra-estruturas, na reclassificação de solos agrícolas em solos urbanizáveis, etc., leva a uma urgente necessidade, por parte dos gestores e planeadores, de informação apropriada e em tempo útil para responder com soluções adequadas e acompanhar esses desenvolvimentos, soluções essas que passarão necessariamente pelas novas tecnologias, as quais, aliadas a métodos de observação *in-situ* deverão oferecer metodologias de produção de cartografia que possam dar resposta a estes desafios.

Uma dessas soluções passa pela utilização de imagens de satélite de alta resolução, para a produção de cartografia de meio urbano. Esta utilização oferece no entanto algumas dificuldades, dada a grande variabilidade espectral e espacial, inerente à natureza desses elementos. Estas características resultam numa relação complexa e heterogénea entre os elementos que compõem o meio urbano e que apresentam um enorme leque de respostas espectrais, com diversas formas e texturas, que resultam em padrões complexos e de difícil exploração exigindo o uso de sensores com uma alta resolução espectral e espacial que permitam uma classificação mais exacta das imagens provenientes desses sensores.

Por sua vez, os métodos de classificação existentes, nomeadamente ao nível do pixel, e que constituem objecto de estudo desta tese, são nesta perspectiva postos à prova, na medida em que se questiona a respectiva adequabilidade à obtenção de geo-informação com qualidade.

Até ao início do séc. XXI, a detecção remota era dominada por sensores acoplados a plataformas aéreas, que apresentavam resoluções espaciais que permitiam discriminar com precisão elementos em meio urbano com resoluções espaciais entre os 0,5 a 10 metros de IFOV (Welch 1982), ficando muito acima das resoluções conseguidas por sensores acoplados a satélites, e.g., *Landsat* (Tabela 1).

Sensor	Resolução Espectral (μm)	Resolução Espacial (m)	Largura de scan (km)	Resolução temporal (dias)	Altitude orbital	Período de operacionalidade
Thematic Mapper	Canal 1: 0,45 - 0,52	30x30				
	Canal 2: 0,52 - 0,60	30x30				
	Canal 3: 0,63 - 0,69	30x30				Lansat 4 16/07/1982 – 02/1983
	Canal 4: 0,76 - 0,90	30x30	185	16	710 km, quasi- polar, hélio- sincrona	
	Canal 5: 1,55 - 1,75	30x30				Landsat 5 01/03/1984 - ?
	Canal 7: 2,08 - 2,35	30x30				
	Canal 6: 10,40 - 12,50	120x120				

Tabela 1- Especificações do sensor Thematic Mapper dos satélites Landsat 4-5

Fonte: http://landsat.usgs.gov/tools_project_documents.php (adapt.)

Só a partir de 1999, com o advento da terceira geração de satélites de observação terrestre, é que os sensores espaciais conseguiram competir com os sensores aéreos, apresentando resoluções espaciais mais elevadas, e.g., *IKONOS* (Tabela 2), *QuickBird* (Tabela 3), dando um enorme contributo no sentido de ultrapassar os limites impostos pelos sensores de média e baixa resolução espacial, ao apresentar um maior detalhe e exactidão para a cartografia de zonas urbanas.

Contudo, estes satélites estão limitados a 4 bandas espectrais, sendo que, segundo Herold *et al.* (2003), as bandas espectrais que permitem uma melhor identificação de classes urbanas de uso e ocupação do solo situam-se fora das fronteiras espectrais dos satélites *IKONOS* e *QuickBird*, donde podem resultar classificações erróneas de certos elementos. Com o intuito de diminuir esta desvantagem, informação complementar como a textura, a forma, ou o contexto espacial pode ser incorporada nas classificações de imagens de alta resolução.

Esta tese pretende contribuir para o desenvolvimento de métodos de classificação mais eficazes e que conduzam a uma maior exactidão nos resultados, que permitam responder a este desafio de crescente necessidade de informação geográfica actualizada e de elevado grau de fiabilidade em meio urbano. Recorrendo a uma imagem *QuickBird* com alta resolução espacial (entre 0.61 m e 2.4 m) de uma zona que abrange as

freguesias do Beato, Marvila e S. João, na cidade de Lisboa (Figura 1), estudámos vários métodos de classificação com vista à obtenção de resultados de forma rápida e precisa.

Sensor	Resolução Espectral (μm)	Resolução Espacial (m)	Largura de scan (km)	Resolução temporal (dias)	Altitude orbital	Período de operacionalidade
	Pancromático: 0,45 - 0,90	1x1				
	Canal 1: 0,45 - 0,50	4x4			681 km, quasi-polar, hélio-síncrona	24//09/1999
	Canal 2: 0,52 - 0,60	4x4	13	≈ 3		
	Canal 3: 0,63 - 0,69	4x4				
	Canal 4: 0,76 - 0,90	4x4				

Tabela 2 - Especificações do satélite IKONOS

Fonte: <http://www.satimagingcorp.com/satellite-sensors/ikonos.html> (adapt.)

Sensor(modos)	Resolução Espectral (μm)	Resolução Espacial (m)	Largura de scan (km)	Resolução temporal (dias)	Altitude orbital	Período de operacionalidade
Pancromático	0,45 - 0,90	0.60				
Multiespectral	Canal 1: 0,45 - 0,52	2.4			450 km, quasi-polar, hélio-síncrona	18/10/2001
	Canal 2: 0,52 - 0,60	2.4	16.5	1 a 3.5		
	Canal 3: 0,63 - 0,69	2.4				
	Canal 4: 0,76 - 0,90	2.4				

Tabela 3 - Especificações do satélite *QuickBird*

Fonte: <http://www.satimagingcorp.com/satellite-sensors/quickbird.html> (adapt.)

O recurso a esta imagem permitiu ir ao encontro dos requisitos de detalhe da cartografia em meio urbano, ao mesmo tempo que com a utilização de uma metodologia de extracção de classes de ocupação e uso de solo recorrendo a múltiplos classificadores pretendemos aumentar a exactidão temática na classificação da imagem.

Esta tese é desenvolvida no âmbito do projecto GeoSat – Metodologias para extracção de informação GEOgráfica a grande escala a partir de imagens de SATélite de

alta resolução¹, promovido pela FCSH/UNL e que tem como objectivo o desenvolvimento de uma metodologia que permita a produção de informação geográfica para fins municipais, com base em imagens de satélites de alta resolução².

Apresentamos esta tese numa estrutura de cinco capítulos onde procuramos contextualizar o tema pela sua relevância e actualidade. No primeiro capítulo ilustramos o objectivo deste trabalho no contexto do projecto onde se insere². Acompanhamos este primeiro capítulo com uma breve referência à metodologia usada, descrevendo o tipo de imagem que utilizámos, a área à qual se refere, bem como os processos de classificação propostos e o *software* utilizado. No segundo capítulo contextualizamos a tese pela análise do estado da arte no que diz respeito a nomenclaturas e metodologias de classificação de imagens de satélite de áreas urbanas que mais se enquadram no âmbito desta tese, identificando as nomenclaturas urbanas relevantes, descrevendo sumariamente o funcionamento dos classificadores utilizados e por último referindo os métodos de avaliação da exactidão dos resultados utilizados. No terceiro capítulo iniciamos a descrição pormenorizada do estudo sobre os classificadores utilizados, também com uma descrição detalhada da área coberta pela imagem e do processo de classificação proposto. No quarto capítulo apresentamos os resultados obtidos acompanhados da respectiva discussão. No quinto e último capítulo concluímos a tese apresentando as principais conclusões do estudo e apontando caminhos para futuros trabalhos que poderão explorar certos aspectos que foram suscitando interesse no decorrer do trabalho.

¹ Tenedório *et al.* (2007) 'GeoSat – Metodologias para extracção de informação GEOgráfica a grande escala a partir de imagens de SATélite de alta resolução'

² O projecto GeoSat visa criar uma metodologia que permita integrar a informação proveniente de imagens de alta resolução num Sistema de Informação Geográfica (SIG), com o objectivo final de facilitar a actualização de cartografia de base, a partir da qual será posteriormente produzida cartografia temática, num processo que se pretende expedito e com rigor temático. Desta forma, o projecto pretende criar uma base metodológica que permita a utilização de imagens de alta resolução em dois níveis de cartografia: um 1º nível, de cartografia de grande precisão, apresentando cartografia com elevada precisão temática e geográfica, disponibilizando informação geográfica que se prevê imutável (rede estradas, áreas urbanas consolidadas, etc.), a ser actualizada em intervalos de tempo mais longos (e.g., 10 anos); e um 2º nível, de actualização periódica de curto prazo (e.g., 1 ano), com geoinformação retirada de imagens de satélite, disponibilizando uma alta precisão temporal em detrimento da precisão geográfica e temática, cuja performance será inevitavelmente inferior à registada na cartografia que será possível obter a partir do nível 1.

Capítulo I: Objecto e Metodologia

O objecto de estudo desta tese centra-se na avaliação de classificadores supervisionados *pixel a pixel*, nomeadamente os que se encontram disponíveis no *software* ENVI (Tabela 4). Focalizámos este estudo somente na utilização de classificadores *pixel a pixel* com o intuito de mitigar limitações na utilização de classificadores deste tipo em imagens de alta resolução espacial. De entre os classificadores *pixel a pixel*, utilizámos unicamente os supervisionados, dado permitirem a selecção de parcelas de treino³ espectralmente representativas das classes que se queiram classificar.

Modo	Tipo	Nome
		Paralelepípedo
		Mínima Distância
		Distância Mahalanobis
Supervisionado	<i>Pixel a pixel</i>	Máxima Verosimilhança
		Mapeamento de Ângulo Espectral
		Codificação Binária

Tabela 4 - Classificadores supervisionados disponíveis no software ENVI

Como referido no capítulo anterior, utilizámos uma imagem do satélite QuickBird, adquirida a 14 de Abril de 2005, e que foi alvo de uma fusão entre a imagem pancromática e as bandas multiespectrais, conseguindo com este processo uma resolução geométrica de 0.61 m. Esta operação não foi alvo de estudo nesta tese, tendo sido utilizada a imagem resultante da fusão como imagem de partida.

As principais operações para a classificação da imagem efectuadas foram: extracção de parcelas de treino de classes acompanhada por um processo iterativo de refinamento da representatividade da amostra para as classes em questão e da consequente separabilidade entre classes; e o uso dos classificadores supervisionados ao nível do pixel.

³ Do inglês “training áreas” – designa um conjunto de pixéis representativos de um determinado tema ou classe (ver capítulo II.3).

Construímos um mapa de referência com todas as classes escolhidas no software ArcGIS, que serviu posteriormente para comparar com as imagens resultantes das classificações, para assim inferir sobre a exactidão temática das mesmas. A avaliação da exactidão das classificações foi feita recorrendo a dois tipos de abordagens: usando a clássica matriz de confusão⁴ (Lillesand e Kiefer, 1994) e o índice de concordância Kappa⁵ (Cohen, 1960).

Optámos pela criação de um método de classificação que tivesse a capacidade de incorporar regras de decisão que nos ajudassem na obtenção dos melhores resultados (ver capítulo III.2). Essa representação esquemática do processo de classificação foi alimentado por uma nomenclatura de classes estratificada por níveis extraindo a cada nível o melhor resultado, usando subsequentemente as classes do nível anterior como máscaras para classificar as classes posteriores dependentes, i.e. as classes de um nível foram utilizadas como máscaras para minimizar o erro de classificações erróneas para as classes dependentes.

⁴ Ferramenta usada para a avaliação de exactidão de uma classificação (ver capítulo II.4).

⁵ Medida de concordância que indica quantas observações se afastam das esperadas (ver capítulo II.4).

Capítulo II: Nomenclaturas e metodologias de classificações de uso do solo urbano em imagens de satélite: um estado da arte

II.1 Corpus bibliográfico de referência

A Biblioteca do Conhecimento Online⁶ (B-On) é uma base de dados de publicações científicas que disponibiliza a instituições de investigações e de ensino superior periódicos científicos internacionais e e-books de fornecedores de conteúdos, permitindo potenciar a visibilidade e acessibilidade de resultados da actividade científica da maior qualidade e rigor científico.

A B-On foi, neste contexto, a nossa opção de fonte para o trabalho de investigação que realizámos. Nela pesquisámos artigos que considerámos relevantes para adquirir o necessário conhecimento de estudos e resultados sobre o tema no qual nos propusemos trabalhar. Seleccionámos, para tal, quatro periódicos que abarcam a área da detecção remota. Foram eles: o *International Journal of Remote Sensing* (o periódico oficial da Sociedade de Detecção Remota e Fotogrametria do Reino Unido); o *Remote Sensing of Environment*; o *IEEE Geoscience and Remote Sensing Letters*; e o *IEEE Transactions on Geoscience and Remote Sensing*.

A recolha de informação relevante para a presente tese teve em conta duas condicionantes principais: em primeiro lugar, as características de centro urbano da área abrangida pela imagem (e.g. zonas habitacionais, espaços verdes, serviços, etc.); e em segundo lugar, o facto de o tipo de imagem com que trabalhámos ser proveniente de satélites que só estiveram disponíveis a partir de 2001. Neste contexto, e dando espaço a alguma maturação na aquisição de imagens e à publicação de trabalhos onde este tipo de imagem com foco em centros urbanos foram utilizadas, balizámos a nossa recolha no período entre 2003 e 2010, sem prejuízo de, sempre que considerámos necessário para aprofundar e enriquecer o nosso trabalho, termos alargámos os horizontes da nossa investigação.

⁶ <http://www.b-on.pt>

Chaves
Urban Classification
Urban area
Urban
Urban landscape
Urban land cover
High resolution
High spatial resolution
QuickBird
Ikonos
VHR
Classification VHR
Classification QuickBird
Classification IKONOS
Classification features
Classes
Features
Segmentation
Land use
Urban remote sensing
Urban remote sensing and land use
Classification

Tabela 5 - Chaves de pesquisa

Numa primeira fase efectuámos uma pesquisa aberta limitada apenas às condicionantes referidas utilizando uma tabela de chaves de pesquisa (Tabela 5) que considerámos relevante. Numa segunda fase procurámos publicações sobre temas relevantes para a presente tese, como por exemplo aplicações de diversas metodologias de extracção de informação de imagens provenientes de satélites de alta resolução espacial, exploração de sinergias entre diversos classificadores, utilização de informação complementar para melhorar as classificações, estudos sobre as características espectrais de elementos presentes em imagens de satélite, nomenclaturas de classes propostas para a classificação de meios urbanos e classificadores supervisionados ao nível do pixel.

No próximo capítulo iremos descrever de forma sucinta os trabalhos seleccionados, destacando os aspectos que considerámos mais importantes no âmbito desta tese, nomeadamente as nomenclaturas de classes utilizadas para a classificação de imagens e estratégias seguidas pelos autores.

II.2 Nomenclaturas urbanas

O meio urbano está sujeito a constantes mudanças, que têm a sua origem em acções de expansão, de requalificação, de reabilitação, etc. Apesar desta transfiguração dinâmica, podemos afirmar que existem certos temas que caracterizam os centros urbanos que se mantêm imutáveis ao longo do tempo, e.g., estradas, edificado, espaços verdes, passeios, etc. Contudo, essas características têm particularidades que se expressam ao nível do país e mais concretamente da cidade, i.e., não poderemos classificar, de uma maneira linear, todas as cidades recorrendo a uma comparação com um mesmo conjunto de parcelas de treino.

Neste trabalho estudámos previamente as características específicas da cidade de Lisboa, nomeadamente da área abrangida pela imagem *QuickBird* que utilizámos, uma zona que abrange áreas das Freguesias do Beato, Marvila e S. João (Figura 1), com zona habitacional onde se destaca uma zona de vivendas com uma peculiar forma em leque, zonas verdes, zonas industriais, serviços e escolas.

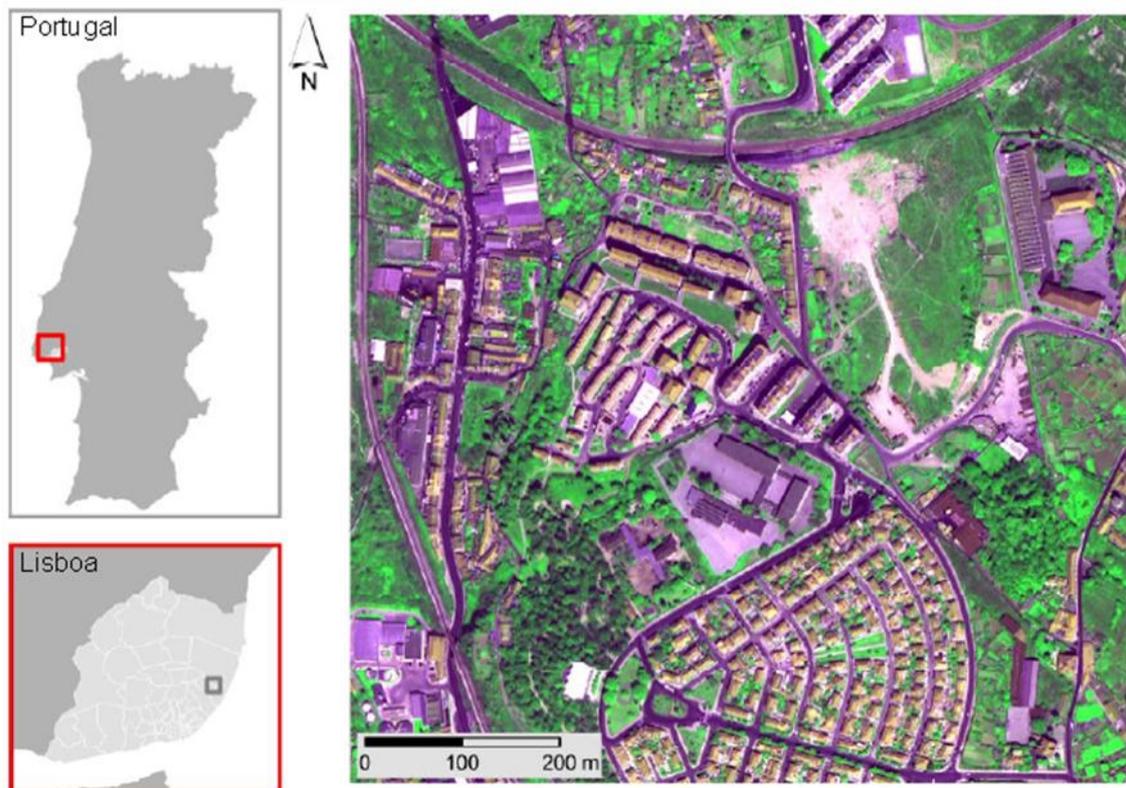


Figura 1 - Imagem QuickBird utilizada⁷

Fonte: Freire *et al.* (2010) (adapt.)

Com o intuito de auxiliar a selecção das classes que melhor pudessem caracterizar a área em estudo, procurámos encontrar nos trabalhos seleccionados, nomeadamente trabalhos sobre centros urbanos, exemplos de nomenclaturas urbanas que nos permitissem construir uma nomenclatura específica para a imagem em causa, que aliasse as características particulares da zona abrangida com o detalhe proveniente da resolução espacial da imagem utilizada.

Carleer e Wolff (2006) estudam um método de selecção de classes para assim seleccionar as que melhor caracterizam uma determinada zona, com o intuito de melhorar a classificação de imagens de alta resolução espacial de zonas urbanas. Carleer e Wolff (2006) sublinham a importância que tem a inclusão de informação complementar na classificação de imagens de alta resolução espacial, e.g., *IKONOS*, *QuickBird*, *OrbView-3*. Esta importância, segundo os autores, torna-se mais premente

⁷ Cedida pelo Centro de estudos geográficos da Faculdade de Ciências Sociais e Humanas

devido à restrição que advém deste tipo de sensores, limitados a 4 bandas espectrais, que por si só não permitem explorar os detalhes urbanos na sua dimensão espectral.

Para fazer face à complexidade dos padrões urbanos, na sua forma, tamanho, e interrelações, poder-se-á recorrer a informação espectral noutras regiões mais indicadas para este fim, que segundo os autores se encontram na região do infravermelho de frequências curtas e o infravermelho térmico, pois encerram importantes características espectrais que permitem identificar diversos materiais bem como informação térmica do meio urbano. Contudo, mesmo recorrendo a sensores hiper-espectrais existem limitações ao nível da resposta espectral de alguns elementos urbanos, que sendo na realidade diferentes podem apresentar respostas espectrais semelhantes, (e.g., a água, as estradas, ou mesmo alguns prédios podem confundir-se com a resposta espectral da sombra) facto que necessariamente irá resultar numa classificação errada dos elementos.

Os autores enfatizam a importância de, usando imagens de alta resolução espacial, se utilizar informação complementar, como por exemplo a forma, o tamanho, a textura, a sombra, a localização, a associação, etc., características que o ser humano naturalmente interpreta. Esta informação tem um papel de extrema relevância na ajuda à classificação de uma imagem para distinguir entre classes com uma resposta espectral muito semelhante.

Revela-se particularmente importante neste estudo a estratégia de segmentar a imagem em vários níveis. A justificação prende-se com o facto de com a segmentação poder-se unir regiões mais homogéneas, permitindo que estas novas regiões sejam posteriormente classificadas ou segmentadas para um novo nível. Neste sentido, a cada nível podem ser exploradas características que de outro modo não seriam identificadas, ajudando a uma maior precisão na classificação da imagem.

Carleer e Wolff (2006) exploraram as características que, calculadas depois da segmentação, melhor se ajustavam à classificação de imagens. Utilizando a segmentação como estratégia para fraccionar as imagens em vários níveis, os autores identificaram assim quais os níveis que melhor caracterizam uma certa classe.

Neste estudo foi utilizada uma imagem *QuickBird* do centro da cidade de *Ghent* (Bélgica). A escolha ficou a dever à presença de vários tipos de elementos urbanos e diferentes materiais no centro da cidade, características relevantes para o objectivo deste estudo.

Os autores adoptaram uma legenda do tipo hierárquico com três níveis (Tabela 6). No primeiro nível incluíram as três principais classes: “vegetação”, “não-vegetação” e “sombra”, os autores justificaram a utilização da sombra para prevenir que os “*píxeis* sombra” fossem classificados como água ou telhados escuros. No nível dois a classe “sombra” é dividida em “vegetação” e “não-vegetação”. As restantes subclasses do nível dois baseiam-se unicamente na cor e no tipo de vegetação. O terceiro nível apresenta uma subdivisão das classes atrás referidas em áreas de “transporte” e “edificado”.

	Nível 2		Nível 3	
Sombra	1	Vegetação	11	
		Não-Vegetação	12	
Vegetação	2	Arbustos e árvores	21	
		Relva	22	
Não-Vegetação	3	Água	31	
		Superfícies vermelhas	32	Área de transportes 301
		Superfícies muito reflectoras	33	
		Cinza brilhante	34	
		Cinza média	35	Prédios 302
		Cinza escuro	36	

Tabela 6 – Hierarquia de classes adoptada no estudo

Fonte: Carleer e Wolff (2006) (adapt.)

Depois de classificada a imagem, os resultados foram comparados com a classificação visual da mesma, seguindo a legenda proposta. Seleccionaram assim as melhores características para a identificação de elementos de cada uma das classes.

Um outro artigo que explora a textura e as estatísticas espaciais numa classificação orientada por objectos, utilizando imagens de alta resolução espacial de áreas urbanas, apresenta-nos uma legenda mais simples que a anterior, mas com elementos comuns (Su *et al.*, 2008).

Neste estudo, os autores evidenciam a realidade heterogénea dos meios urbanos, composta por malhas complexas de edifícios, árvores, relva, etc., e a dificuldade de extrair informação sobre a textura por métodos tradicionais de classificação espectral.

Para minimizar este facto apontam como uma possível solução a inclusão de informação espacial que caracterize os elementos urbanos pertencentes às classes definidas para assim melhorar as classificações. Propõem-se assim, analisar uma

imagem com recurso a estatísticas de textura e estatísticas locais com vista a aperfeiçoar a classificação orientada por objectos.

Su *et al.* (2008) recorrem a uma série de características de textura utilizadas para descrever propriedades espaciais usando uma matriz de co-ocorrências de níveis de cinzento⁸, sendo elas a homogeneidade, contraste, segundo momento angular e entropia. Estas características são consideradas as mais indicadas para a classificação em meio urbano. Utilizam também uma característica espacial local – *Moran's* – um indicador espacial estatístico que reflecte as diferentes estruturas espaciais de suavidade e rugosidade das superfícies. A imagem utilizada neste estudo é proveniente do satélite *QuickBird* adquirida em 2004 do centro da cidade de Kuala Lumpur, Malásia. A cidade com um índice demográfico elevado (cerca de 6502 habitantes por km²) apresenta-se fortemente urbanizada, com zonas verdes espalhadas por toda a cidade. Os autores identificaram 7 tipos de classes presentes na imagem em questão chegando a uma legenda que contém classes como a água, vegetação rasteira, relva, edifícios, solo a descoberto e estradas.

Kux *et al.* (2006) recorrem a imagens de alta resolução *QuickBird* de 2002 e 2004, para estudar a forte pressão urbanística a que estão sujeitas duas áreas de Belo Horizonte, Belvedere e Buritis, no estado de Minas Gerais.

Belo Horizonte tem cerca de 2 milhões de habitantes sendo a sexta cidade mais populosa do Brasil, apresentando os esperados sintomas de um grande centro urbano, tais como fortes pressões demográficas, construções desordenadas, avanço de solos impermeáveis, diminuição de espaços verdes, etc. Tais factos carecem de óbvios mecanismos de monitorização com vista a um planeamento urbano mais eficiente e célere. É neste sentido que Kux *et al.* (2006) avaliam o recurso a imagens de alta resolução para uma classificação automática, no que diz respeito à qualidade da informação obtida. Recorre para isso, a uma classificação orientada por objectos, técnica que relaciona e agrupa conjuntos de *píxeis* contextualmente coerentes em unidades chamadas de “objectos”. Sendo a classificação baseada em “objectos”, torna-se assim uma classificação mais próxima de uma interpretação visual feita por um operador.

⁸ Do inglês, grey-level *co-occurrence matrix*

Kux *et al.* (2006) definiram um conjunto de classes (Tabela 7) baseando-se na interpretação visual de imagens de satélite e orto-fotos e no conhecimento do terreno. Foram usadas características como a cor, a forma, a textura, a sombra, para elaborar interpretadores que ajudaram na segmentação das imagens. Neste processo os autores apresentam uma hierarquia de classes estruturada pelas relações e dependências entre classes (Figura 2). Os níveis mais altos são ocupados por classes que representam elementos com uma maior separabilidade, sendo que, à medida que se vai descendo de nível, essa separabilidade tendencialmente diminui. Esta estratégia, segundo Kux *et al.* (2006), permite diminuir os erros inerentes a classificação dos elementos, sendo que as classes que se apresentam mais difíceis de discriminar foram remetidas para níveis inferiores. Todo este processo permitiu que se fosse ajustando o modelo hierárquico com o intuito de compreender melhor as tensões que poderiam existir entre os elementos na classificação, podendo assim levar a um refinamento do próprio modelo.

Classe	Descrição
Vegetação arbórea	Forte resposta na banda do infra-vermelho. Existência de textura devido à altura das árvores que resultam (sombra). Distingue-se facilmente das outras classes.
Relva	Forte resposta na banda do infra-vermelho. Uniforme. A textura apresenta-se mais suave o verificado na vegetação arbórea.
Telha de cerâmica	Forma geométrica simples. Variações no tom cor-de-laranja característico. Textura suave. Fácil identificação visual.
Solo a descoberto	Solo em preparação para a construção. Forma irregular. Textura variável e localização aleatória.
Asfalto	Utilizado pelo cadastro urbano para delimitar as estradas. Avenidas e ruas. Formas lineares e rectas.
Sombra	Baixo brilho. Perto de prédios altos e vegetação arbórea.
Piscinas	Forte resposta na banda do azul e por vezes na banda do verde. Bem definidas.
Chapas	Telhados, maioritariamente de amianto e cimento. Nível de quantização perto de 2048.
Coberturas cinzentas	Coberturas de grandes edifícios. Apresentam inúmeras variações.
Coberturas brancas	Elevado brilho. Constituição dos materiais pouco clara.

Tabela 7 - Definição de classes

Fonte: Kux *et al.* (2006) (adapt.)

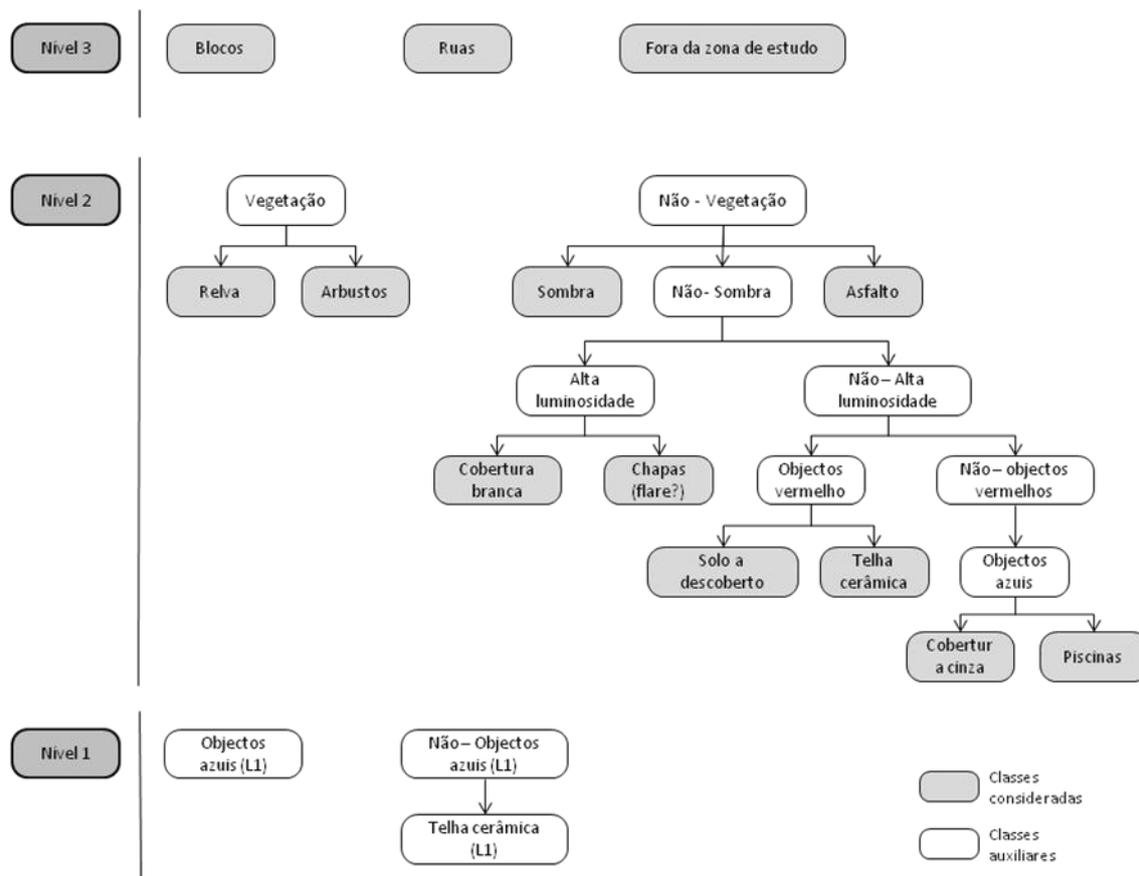


Figura 2 - Rede hierárquica
Fonte: Kux et al. (2006) (adapt.)

Utilizando também uma metodologia orientada por objectos, Zhou e Troy (2008) recorrem a imagens provenientes de um sensor que opera na zona do visível e infra-vermelho de alta resolução espacial acoplado a uma plataforma aérea, informação proveniente de LIDAR⁹, e informação espacial complementar, para a “análise e caracterização do uso e ocupação do solo ao nível da parcela”¹⁰. As imagens provenientes deste sensor activo apresentam três bandas espectrais, duas no visível (verde e vermelho) e uma no infra-vermelho próximo, com uma resolução espacial de 0.6m.

A área de estudo compreende a bacia hidrográfica de *Gwynns Falls* e áreas da cidade de *Baltimore* e *Baltimore County*, áreas situadas na parte norte do estado de

⁹ Do inglês, LIght Detection and Ranging. Sensor óptico que permite medir distância a outros objectos por intermédio de um feixe de luz.

¹⁰ Zhou and Troy (2008) 'An object-oriented approach for analysing and characterizing urban landscape at the parcel level', *International Journal of Remote Sensing*, 29:11,3119 – 3135, pág. 1

Maryland, U.S.A., caracterizadas essencialmente por zonas rurais, suburbanas e urbanas.

Zhou e Troy (2008) utilizam neste trabalho uma abordagem orientada por objectos com o intuito de explorar a inclusão de informação complementar, nomeadamente informação espacial ao nível da parcela, dada a característica unitária da mesma como elemento de análise da paisagem urbana. Assim, os autores pretendem usar a parcela para a segmentação dos objectos tratando-a, como uma “unidade geográfica com um significado funcional” que compõe a realidade paisagística.

Os autores identificaram 5 classes para a classificação das imagens neste estudo (Tabela 8). Para efectuar a segmentação das imagens criaram regras de classificação que permitiram classificar os objectos nas respectivas classes, baseadas em características inerentes ao tipo de informação recolhida, e.g., informação sobre o índice de NDVI¹¹, respostas espectrais, e a outras características, tais como medidas estatísticas e relações espaciais. Estas regras permitiram a diferenciação e segmentação das imagens nas várias classes. Os autores organizaram hierarquicamente as classes partindo das mais abrangentes para as mais particulares, com um conjunto de valores de fronteira para as características de cada classe (Figura 3).

Classes
Edifícios
Pavimento
Vegetação grosseira (árvores e arbustos)
Vegetação fina (vegetação herbácea e relva)
Solo a descoberto

Tabela 8 – Legenda de classes

Fonte: Zhou e Troy (2008) (adapt.)

¹¹ Do inglês Normalized Difference Vegetation Index (índice de vegetação)

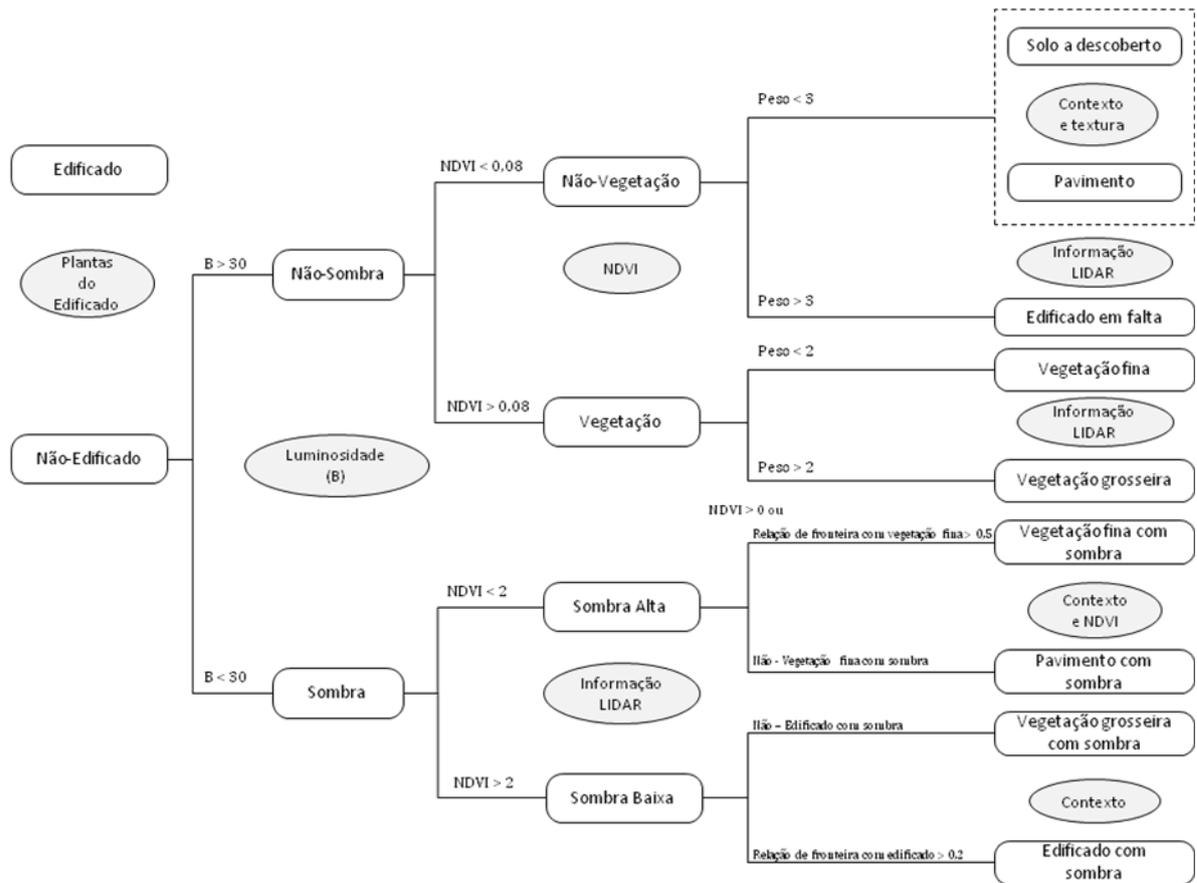


Figura 3 - Hierarquia de classes e respectivas características e regras de separação

Fonte: Zhou e Troy (2008) (adapt.)

Zhou e Troy (2008) começaram por classificar a imagem em duas classes: “edificado” e “não- edificado”. A classe “não- edificado” foi dividida em “sombras” e “não-sombras” recorrendo somente a informação espectral para essa divisão. Os objectos classificados como “não-sombra” são por sua vez subdivididos em ”vegetação” e “não-vegetação” com o auxílio do índice NDVI. Os objectos classificados como “vegetação” são posteriormente diferenciados em dois tipos de vegetação (textura fina e textura grosseira). Os objectos classificados como “não-vegetação” são discriminados como “pavimento”, “solo a descoberto” e “edificado”, com a ajuda de informação contextual e de textura. Para discriminar os objectos classificados como “sombra”, Zhou e Troy (2008) utilizam informação LIDAR para especificar os objectos com sombra “baixa” e sombra “alta”, conseguindo ainda discriminar, com o auxílio de informação do índice NDVI e informação contextual, vegetação com sombra e edifícios com sombra.

Zhou e Troy (2008) utilizam, para avaliar os resultados da classificação efectuada, um mapa de referência classificado visualmente por um operador com base nas cinco classes pré-definidas. Com o mapa de referência e a imagem resultante da classificação calcularam a matriz de confusão e o índice Kappa ao nível do pixel. Obtiveram uma exactidão global da classificação de 92.3% e um índice Kappa de 0.899.

A abordagem seguida pelos autores no que diz respeito à escolha e estruturação da hierarquia de classes pode ser aplicada a outras realidades urbanas, visto que as classes estão vulgarmente presentes em qualquer meio urbano. Assim, afirmam os autores que a hierarquia proposta pode ser ajustada para funcionar com mais classes em diferentes realidades urbanas.

Herold *et al.* (2003) apresentam, na análise que fazem sobre as exigências espectrais para cartografar áreas urbanas, uma avaliação sobre o poder discriminativo de sensores de alta resolução espectral para tratar realidades urbanas em toda a sua complexidade.

O estudo acentua como dificuldade acrescida para a classificação de áreas urbanas, o desconhecimento das propriedades espectrais dos materiais que a compõem. Contudo, com o aparecimento de sensores com características que permitem explorar espectral e espacialmente as propriedades desses materiais, abrem-se novas possibilidades para a classificação de imagens provenientes desse tipo de satélites. Neste sentido, este estudo explora as capacidades dos sensores para discriminar espectralmente a superfície urbana procurando identificar as bandas espectrais mais indicadas para cartografar a mesma.

Para conhecer as propriedades dos materiais, Herold *et al.* (2003) constroem uma biblioteca espectral constituída por cerca de 6000 medições espectrais de materiais existentes em meio urbano, nomeadamente na área de estudo (telhados, estradas, vegetação, etc.). Essas medições foram feitas por um espectrómetro com um alcance espectral entre 350 e 2500 nanómetros¹², utilizando para a biblioteca as mesmas bandas espectrais do sensor com o qual foram adquiridas as imagens da área de estudo, o sensor *AVIRIS*¹³.

¹² 1 nanómetro = $1,0 \times 10^{-9}$

¹³ Do inglês Airborne Visible/Infrared Imaging Spectrometer

No estudo comparativo, Herold *et al.* (2003) pretendem avaliar as capacidades espectrais de sensores hiper-espectrais, nomeadamente do *AVIRIS*, recorrendo para isso a classificações onde utilizam as mesmas bandas espectrais existentes nos sensores multi-espectrais *IKONOS* e *Landsat Thematic Mapper*, com o intuito de inferir sobre as potencialidades que estes possam possuir para cartografar áreas urbanas.

Para este trabalho utilizaram imagens de *Santa Barbara* e *Goleta* (Califórnia - USA). As áreas abrangidas pelas imagens são constituídas por paisagens naturais, zonas de agricultura, zonas de coberto arbustivo e um lago. Têm também zonas residenciais, comerciais e educacionais, cujas superfícies apresentam uma grande variedade de materiais.

Herold *et al.* (2003) apresentam uma hierarquia de classes (Tabela 9) organizada em quatro níveis com 26 classes. Os dois primeiros representam as classes gerais e funcionais. Os níveis seguintes englobam classes mais específicas da realidade urbana, discriminando inclusive o tipo de materiais.

A informação para este estudo foi adquirida por um sensor aéreo *AVIRIS*, em 2000, com uma resolução espacial de cerca de 4m. Este sensor proporciona informação em 224 bandas espectrais numa região do espectro electromagnético (Figura 4) entre 370 a 2510 nanómetros. Os dados, para estudar as potencialidades dos sensores *IKONOS* e *Landsat Thematic Mapper*, foram simulados extraíndo as respectivas bandas espectrais fornecidas pelo sensor *AVIRIS*.

Nível 1	Nível 2	Nível 3	Nível 4
Áreas contraídas	Telhados de prédios	Telhados de materiais compósitos	Telha castanha/vermelha
			Telha cinzenta/branca clara
			Telha cinzenta/preta escura
			Telha cor-de-laranja
		Telhados de gravilha	Gravilha cinzenta
			Gravilha vermelha
		Telhados de metal	Metal castanho
			Metal cinzento claro
		Telhados de asfalto	Cinzento claro
		Telhados de telha	Vermelha
			Cinzento / castanho
		Telhados de alcatrão	
	Telhados de placas de madeira		
	Áreas de transporte	Estradas de asfalto	Asfalto claro (antigo)
			Asfalto escuro (novo)
			Estradas de cimento
Estradas de gravilha			
Parques de estacionamento			
Caminhos-de-ferro			
Infra-estruturas de desporto		Campos de ténis	
	Pistas de tartan		
Vegetação	Vegetação verde		
	Vegetação não-fotosintética		
Superfícies não-urbanas	Solo a descoberto		
Corpos de água	Corpos de água naturais/quasi-naturais		
	Piscinas		

Tabela 9 - Esquema da classificação da imagem para a área em estudo

Fonte: Herold *et al.* (2003) (adapt.)

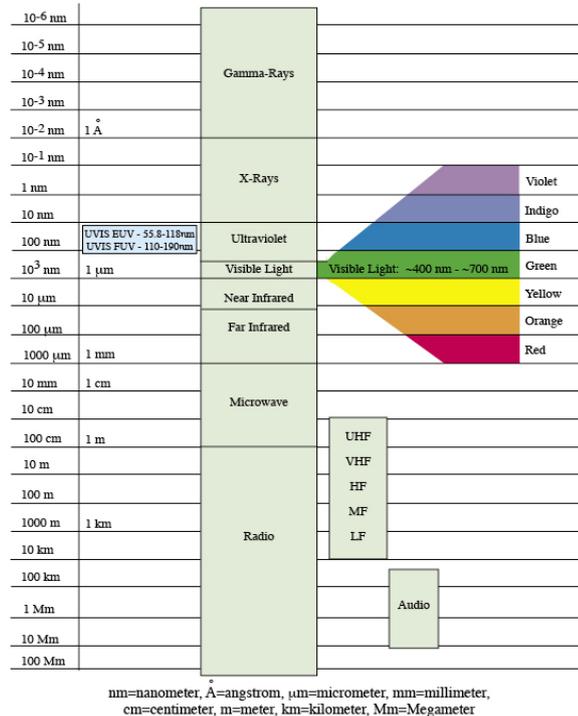


Figura 4 – Espectro electromagnético

Fonte: <http://lasp.colorado.edu/cassini/education/Electromagnetic%20Spectrum.htm>

Herold *et al.* (2003) identificam neste estudo 14 bandas que, pelas suas características, apresentam grandes potencialidades para a classificação em meio urbano, sendo que a maioria se situa “fora ou no limite do alcance espectral de sensores como *IKONOS* ou *Landsat TM*¹⁴. Sublinham também o facto da similitude das respostas espectrais de certos materiais resultarem em classificações erradas, mesmo com a riqueza de sensores multi-espectrais.

Heiden *et al.* (2007) utilizam imagens hiper-espectrais para explorar as características espectrais específicas de diversos materiais presentes em meio urbano. Para avaliar a consistência das características espectrais de cada um dos materiais identificados, os autores utilizam uma “biblioteca de mais de 21.000 valores espectrais dos materiais de superfície mais utilizados na Alemanha”¹⁵. Com este estudo os autores pretendem explorar as potencialidades da utilização de informação espectral dos

¹⁴ Herold, M., Gardner, M. E., and Roberts, D. A., (2003) ‘Spectral resolution requirements for mapping urban areas’, IEEE Transactions on geoscience and remote sensing, vol.41, no.9, pág. 1912

¹⁵ Heiden, U., Segl, K., Roessner, S. and Kaufmann, H. (2007) ‘Determination of robust spectral features for identification of urban surface materials in hyperspectral remote sensing data’, Remote Sensing of Environment, 537-552, pág. 1

materiais no refinamento de metodologias automáticas e semi-automáticas para melhorar a exactidão na identificação e extracção de elementos urbanos.

Heiden *et al.* (2007) sublinham a importância de conhecer a realidade multi-variada dos materiais que compõem a realidade urbana para o planeamento de uma cidade. As imagens hiper-espectrais possibilitam, dada a alta resolução espectral, uma exploração de particularidades específicas dos materiais urbanos.

Neste estudo são exploradas imagens provenientes do sensor aéreo *HyMap*¹⁶ das cidades Alemãs de Desdren e Postdam. Estas cidades possuem uma variedade interessante de elementos urbanos para o objectivo deste estudo. As imagens foram adquiridas numa janela espectral, que passa pelas bandas do visível, infra-vermelho próximo e infra-vermelho curto, com cerca de 128 bandas espectrais, tendo uma resolução de cerca de 4 metros.

Heiden *et al.* (2007) enfatizam a importância, na construção de uma biblioteca espectral, em conhecer em detalhe as características espectrais dos materiais da zona de estudo. Nesse sentido, desenvolveram um sistema hierárquico para qualificar os vários materiais existentes na área de estudo (Figura 5). No primeiro nível dessa hierarquia surgem duas classes principais que dividem os elementos em zonas “impermeáveis” e zonas “não-impermeáveis”. Da classe das zonas “impermeáveis” aparecem num segundo nível duas classes, “edificado” e “áreas a descoberto”. A classe “edificado” contém no terceiro nível a classe “telhados”. Por seu lado, a classe “áreas abertas” contém as classes “totalmente impermeável” e “parcialmente impermeável”. As classes “vegetação” e “não-vegetação”, sub-classes no segundo nível pertencentes à classe “não-impermeáveis”, abrangem as seguintes sub-classes do terceiro nível: “espaços verdes” e “árvores e arbustos”, pertencentes à classe vegetação e “solo a descoberto” e “água”, classes pertencentes à classe “não-vegetação”. É no quarto nível que Heiden *et al.* (2007) exploram os materiais de elementos pertencentes às classes do terceiro nível.

¹⁶ HyMap é um sensor hyper-espectral de carácter comercial desenvolvido pela empresa Integrated Spectronic Sydey, Austrália, munido com 128 bandas com uma resolução espectral de cerca de 17nm, e uma resolução espacial entre 3 a 10m.

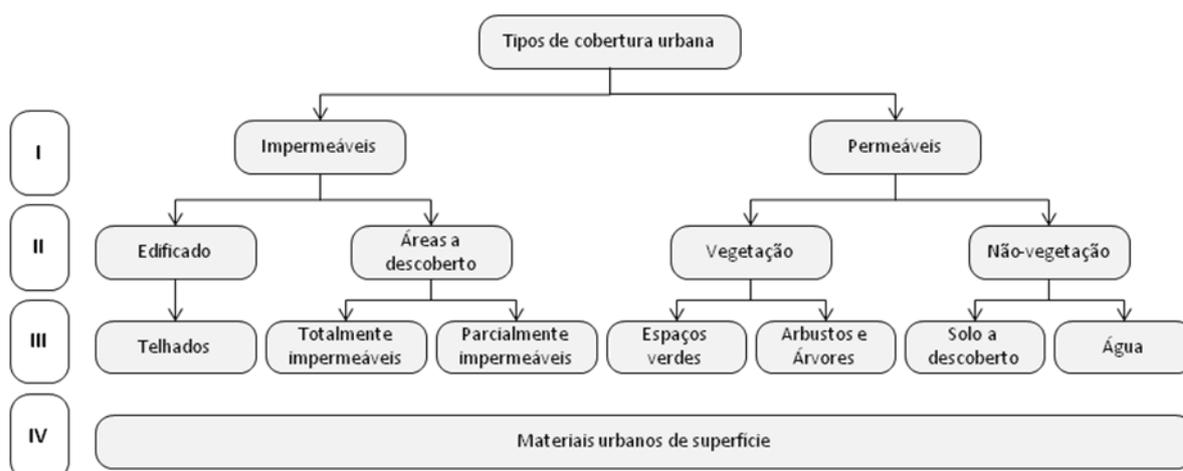


Figura 5- Caracterização hierárquica de materiais urbanos de superfície

Fonte: Heiden *et al.* (2007) (adapt.)

Os vários materiais que compõem a realidade urbana das cidades alemãs em estudo foram sujeitos a medições espectrais, efectuadas por um espectrómetro com capacidade para registar medições em cerca de 2151 bandas num intervalo entre $0,35\mu\text{m}$ e $2,50\mu\text{m}$ ¹⁷ do espectro electromagnético (Figura 4). Recolheram-se amostras espectrais de vários materiais na zona de teste. Com a informação recolhida identificaram os respectivos elementos e classes nas imagens em questão.

Heiden *et al.* (2007) concluem que as características mais comuns podem ser identificadas nas imagens, apesar da grande variabilidade espectral destas, quando comparadas com as medições no terreno, facto que se deve principalmente a factos como à iluminação dos objectos, às diferentes datas de aquisição, e à variabilidade espectral dos materiais.

Blumberg, e Zhou (2007) propõem uma abordagem para a classificação de imagens de satélite - no caso concreto deste estudo utilizam uma imagem que abrange a cidade de Beer-Sheva, Israel - que permita a interligação entre três áreas de processamento na detecção remota: classificação física (ao nível do pixel); extracção semântica (ao nível dos objectos); e o reconhecimento de informação (ao nível da imagem). Neste sentido, os autores pretendem extrair informação da imagem em vários níveis de segmentação, fazendo interagir a informação espacial e espectral a diferentes

¹⁷ Micrómetro – miliolésima parte do metro (10^{-6})

escalas, agregando essa informação em unidades semânticas lógicas, i.e., em classes temáticas pré-definidas.

Os autores sublinham as mais-valias do método proposto, dada a clara vantagem na utilização do conceito de “objecto” (conjunto de *píxeis* com sentido semântico) como sendo um processo mais próximo da classificação visual humana, e também o facto de poderem analisar as relações entre objectos, resultando assim necessariamente em classificações mais precisas.

Na metodologia proposta, Blumberg e Zhou (2007), definem como objectivo “a integração, numa única plataforma, das operações de classificação, extracção semântica e reconhecimento de informação da imagem, efectuando segmentações de modo sincronizado e interactivo”. Sublinham ainda o importante papel dos objectos criados ao longo do processo, em detrimento dos *píxeis*, e da análise das relações entre os *píxeis* que compõem esses objectos a diferentes escalas hierárquicas.

A área de estudo de Blumberg e Zhou (2007) compreendem uma zona desértica situada a norte do deserto de Negev e parte da cidade de Beer-Sheva, Israel. Foram utilizadas imagens provenientes do sensor ASTER¹⁸, utilizando três bandas no visível e seis no infra-vermelho curto.

Blumberg e Zhou (2007) identificaram, para este estudo, seis classes que habitualmente caracterizam o meio urbano: “urbano impermeável”, “ruas e estradas”, “vegetação urbana”, “solos urbanos”, “áreas suburbanas” e “corpos de água”. Como seria de esperar os autores apresentam classes características de centros urbanos adequadas ao local de estudo. Na Figura 6 podemos ver a “árvore de decisão” utilizada neste estudo, nela está representado o esquema hierárquico seguido para a extracção das classes pretendidas no processo de classificação.

Chen *et al.* (2007) apresentam um estudo sobre a exactidão de métodos de classificação orientada por objectos, concretamente na classificação e geração de cartografia urbana, procurando apresentar metodologias capazes de dar resposta às necessidades naturais dos modernos centros urbanos.

Os autores utilizam uma imagem proveniente do sensor *ASTER* da cidade de Pequim, China, adquirida a 12 de Junho de 2001, como área de teste para este estudo. A

¹⁸Do inglês *Advanced Spaceborne Thermal Emission and Reflection Radiometer* <http://www.satimagingcorp.com/satellite-sensors/aster.html>

cidade de Pequim apresenta-se como um óptimo caso de estudo, dado ser uma das maiores cidades chinesas, com cerca de 10.3 milhões de habitantes, onde se assiste a um contínuo crescimento da indústria e do tecido urbano e se pode testemunhar o impacto que estes produzem na cidade.

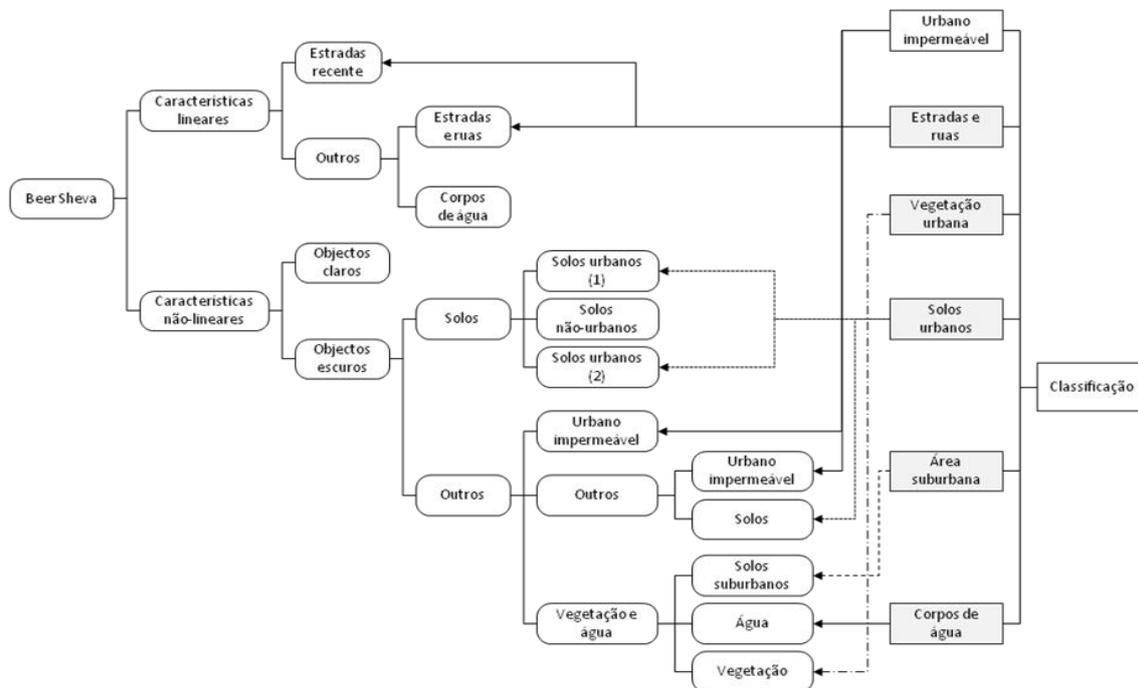


Figura 6 - Árvore de decisão usada no processo de classificação hierárquica

Fonte: Blumberg e Zhou (2007) (adapt.)

Chen *et al.* (2007), dividem o processo seguido para a classificação orientada em objectos em três etapas:

- Segmentação em multi-resolução, onde agregam a informação espectral semelhante em zonas homogéneas, efectuando este processo a várias escalas e conseguindo, assim, discriminar os objectos com mais exactidão;
- Construção de uma hierarquia de classes, conseguindo estruturar a informação espectral em várias classes pré-definidas;
- Classificação utilizando uma “árvore de decisão”, estabelecendo assim regras para a classificação das classes, agrupando a informação espectral numa estrutura hierárquica de classes;
- Avaliação dos resultados da classificação.

Os autores criaram uma hierarquia de classificação com as classes propostas (Tabela 10) em três níveis, numa lógica de “árvore de decisão” (Figura 7), partindo de categorias mais gerais como a “água”, a “vegetação” e a “não-vegetação” continuando a discriminar os temas até chegarem às classes do último nível.

Nível I	Nível II	Nível III
Água	Viveiro de peixes Lago Rio	
Vegetação	Bosque Pastagens Terra agrícola	
Não-vegetação	Impermeável Edificado Solo a descoberto	Urbano de baixa densidade Urbano de alta densidade Locais de construção

Tabela 10 - Sistema hierárquico de classificação

Fonte: Chen e tal (2007) (adapt.)

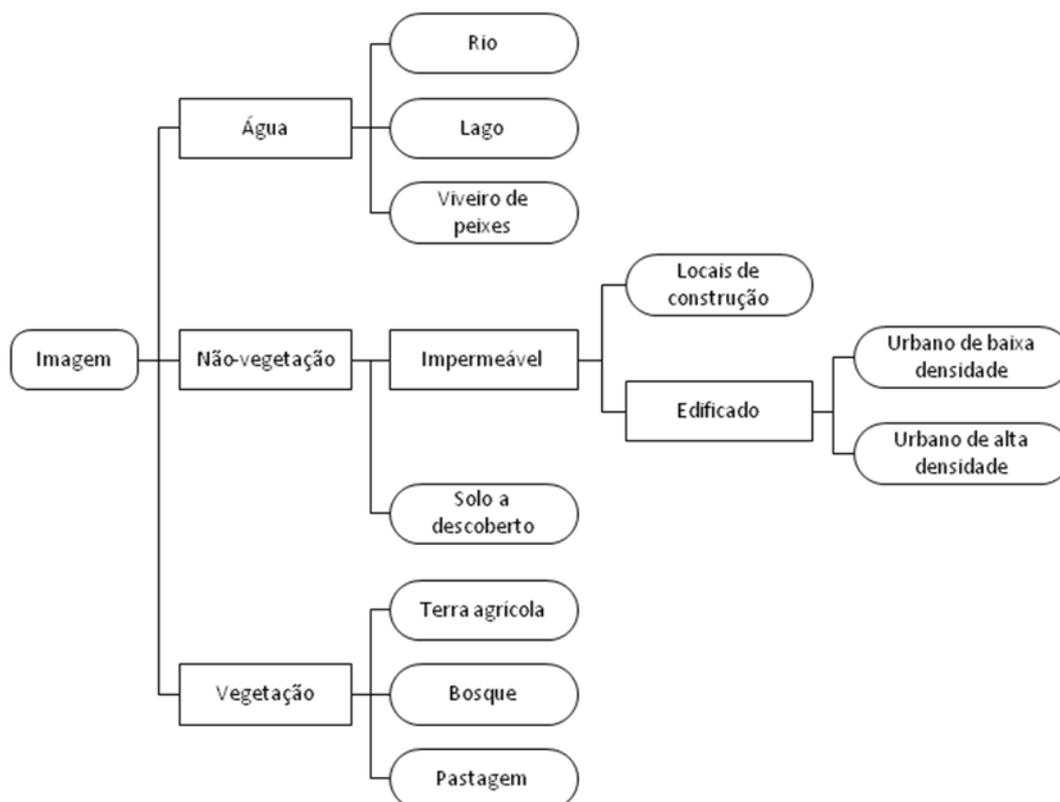


Figura 7- Diagrama de árvore de decisão para classificação

Fonte: Chen *et al.* (2007)

Chen *et al.* (2007), comparam os resultados da classificação com outros métodos convencionais de classificação (e.g. máxima verossimilhança), utilizando para o efeito uma classificação de referência da imagem. As respectivas matrizes de confusão e índices Kappa foram gerados, dando uma precisão de 85% para a classificação orientada por objectos e de 75% para a classificação de máxima verossimilhança. Estes resultados demonstram que para o caso de estudo a melhor classificação é sem dúvida a classificação orientada por objectos.

Dell'Acqua *et al.* (2004) exploram métodos de classificação aplicados a imagens provenientes de sensores hiper-espectrais com o objectivo de melhorar a precisão da informação extraída deste tipo de imagens em áreas urbanas.

A informação hiper-espectral vinda de sensores deste tipo é extremamente rica no que diz respeito à possibilidade de discriminação e classificação de materiais urbanos. Até há bem pouco tempo este tipo de sensores tinha uma resolução espacial muito baixa, não permitindo analisar uma possível exploração das duas resoluções, espectral e espacial, a este nível. Contudo, o aparecimento de sensores de alta resolução espectral e espacial abre uma nova página para o desenvolvimento de novos métodos de classificação e também para o aperfeiçoar dos métodos existentes.

Os autores investigam neste artigo técnicas de multi-classificação para melhorar a precisão da cartografia resultante aplicada a áreas urbanas. Dell'Acqua *et al.* (2004) exploram as sinergias entre classificadores espectrais e espaciais, mais concretamente concentra a classificação na análise espectral e espacial de pequenas zonas da imagem, abordagem a que se dá o nome de “detectores de anomalias locais”¹⁹, englobando posteriormente o resultado dessa análise no processo de segmentação da imagem (detectores globais de anomalias²⁰).

Dell'Acqua *et al.* (2004) utilizam imagens provenientes do sensor hiper-espectral DAIS²¹ de Pavia, norte de Itália, com uma resolução espacial de 2.6m. Este sensor está dotado de 80 bandas incluindo as bandas de do visível e infra-vermelho.

Da análise da área de estudo, Dell'Acqua *et al.* (2004), identificam um conjunto de classes (Tabela 11) que caracterizam a área e procedendo à classificação visual das

¹⁹ Do inglês local anomaly detector

²⁰ Do inglês global anomaly detector

²¹ Do inglês Digital Airborne Imaging Spectrometer

mesmas, recolhem um conjunto de parcelas de treino para a posterior utilização nos processos de classificação.

Classes
Água
Árvores
Asfalto
Parqueamento
Alcatrão
Telhados
Zonas verdes
Solo a descoberto
Sombra

Tabela 11 - Classes para a zona de teste

Fonte: Dell'Acqua et al. (2004) (adapt.)

A pesquisa que realizámos mostrou-nos diversas abordagens na classificação de centros urbanos que exploram metodologias com vista a cartografar os seus elementos caracterizadores, quer na complexidade das suas formas, quer nas suas interrelações, quer na natureza espectral dos mesmos. Com o recurso a imagens de alta resolução espectral e/ou espacial os autores exploraram novas técnicas e/ou melhoraram algumas já existentes na tentativa de aumentar a exactidão dos resultados das classificação das imagens. Estes estudos utilizaram no processo de classificação diversas abordagens, como por exemplo a utilização de informação complementar (formas, textura, etc.); classificações hierarquizadas por níveis temáticos; exploração da riqueza espectral de imagens de alta resolução espectral; árvores de decisão; bibliotecas de informação espectral de elementos caracterizadores da zona em estudo; classificações orientadas por objectos; sinergias entre vários classificadores, etc.

II.3 Classificadores *pixel a pixel*

Como já referido anteriormente, em áreas heterogéneas como o são os meios urbanos, as técnicas convencionais de classificação *pixel a pixel* apresentam algumas debilidades, devido, por um lado, à semelhança espectral de alguns tipos diferentes de coberto urbano e, por outro, devido à variação espectral que poderá existir dentro de uma classe. Estes aspectos encontram-se ainda mais patentes em imagens de alta resolução espacial, como é o caso da imagem *QuickBird* utilizada neste trabalho. Contudo, com a metodologia proposta, que tem por base classificadores supervisionados *pixel a pixel*, procurámos minimizar as aparentes debilidades do uso deste tipo de classificadores em imagens de alta resolução espacial, criando classes segmentadoras em cada nível.

Os classificadores têm como objectivo a caracterização, por processos automáticos, dos pixéis - unidades básicas numa imagem de satélite - que compõem uma imagem em classes representativas dos vários temas que compõem a área coberta pela imagem. Dentro da família dos classificadores, centrámo-nos, por ser objecto de estudo da tese, no conjunto daqueles que utilizam como base para a classificação o reconhecimento espectral de padrões, (i.e., conjunto de pixéis semelhantes). Estes tipos de classificadores subdividem-se em duas categorias distintas: classificadores supervisionados e não-supervisionados. Começaremos por fazer uma breve referência aos classificadores não-supervisionados, apesar de estarem fora do âmbito da tese.

II.3.1 Classificadores não-supervisionados

Nos classificadores não-supervisionados, é o próprio classificador a identifica as amostras espectrais distintas que poderão existir na imagem num processo iterativo. Dos classificadores não-supervisionados os mais utilizados são o *K-means* e o ISODATA, também chamados e algoritmos de agrupamento²². Neste tipo de classificadores o objectivo é agrupar amostras espectrais semelhantes em grupos estatisticamente separáveis. Essas amostras espectrais não são conhecidas à partida, podendo o número de amostras espectrais ser um parâmetro configurável. Depois de efectuada a classificação o utilizador terá de inferir sobre a natureza das classes que o algoritmo

²² Do inglês *clustering*

classificou, i.e, fazer corresponder a cada classe identificada pelo algoritmo um tema que caracterize uma classe presente na imagem, e agrupar, se for o caso, algumas classes classificadas numa só, se se verificar que poderão fazer parte de um tema único.

De uma maneira geral, estes classificadores começam por calcular as médias de amostras iniciais de pixéis que se destacam pelo facto de se apresentarem uniformemente distribuídas na imagem. De seguida associam cada pixel da imagem à amostra espectralmente mais próxima, criando assim um novo conjunto de amostras. Depois, com as novas amostras, recalculam as respectivas médias. Estes dois últimos passos são repetidos de modo iterativo até as distâncias entre os pixéis e as médias das amostras serem menores do que um limite determinado pelo utilizador.

II.3.2 Classificadores supervisionados

Numa classificação supervisionada a primeira tarefa a ser realizada é a de seleccionar conjuntos de pixéis capazes de descrever espectralmente as classes que se querem classificar. A esses conjuntos dão-se o nome de parcelas de treino. Essa selecção poderá ser efectuada quer por fotointerpretação, quer por consulta de mapas ou através de visitas de campo. Estas amostras servem posteriormente para guiar os classificadores na atribuição dos pixéis da imagem às respectivas classes. Podemos resumir o processo de classificação supervisionada em três passos principais:

1. Selecção de parcelas de treino
2. Classificação da imagem
3. Avaliação de resultados

A escolha das parcelas de treino (passo 1) requer uma atenção redobrada, pois da qualidade espectral dessas amostras dependem os resultados dos classificadores. Existe uma relação delicada entre a importância da homogeneidade das parcelas de treino de uma determinada classe e a sua variabilidade espectral, que garantirá a aproximação à natureza da classe. Para ajudar na escolha e refinamento da selecção das parcelas de treino, o operador poderá recorrer a uma ou mais das seguintes estratégias de análise:

- Representação gráfica espectral das parcelas de treino:

As parcelas de treino podem ser representadas graficamente na forma de histogramas com a distribuição espectral das parcelas para cada banda da imagem. Podem-se também representar a frequência espectral ou indicadores estatísticos (e.g., média, desvio padrão ou variância) das várias classes num só gráfico, podendo observar, por exemplo, as sobreposições entre parcelas de treino de diferentes classes.

Na procura da melhor combinação entre bandas, podemos recorrer a diagramas de dispersão. Estes mostram-nos a correlação entre bandas, permitindo assim escolher a melhor combinação de bandas para uma determinada classe.

- Medidas de separabilidade:

Uma análise de separabilidade entre parcelas de treino, permite estimar o erro esperado na classificação e refinar a representatividade das parcelas de treino. Existem várias medidas estatísticas de separabilidade, nomeadamente, a distância Mahalanobis, distância Euclidiana, distância de Battacharya, divergência transformada e distância Jeffries Matusita²³. Das medidas mencionadas a mais simples é sem dúvida a distância Euclidiana que considera para o seu cálculo as médias das parcelas de treino. Todas as outras medidas implicam cálculos de matrizes de variâncias e co-variância²⁴, assumindo uma distribuição normal²⁵ das parcelas de treino. Em geral, na avaliação dos resultados destas medidas, quanto maior for a separabilidade entre parcelas de treino maior é a probabilidade de uma correcta classificação das respectivas classes. Lillesand e Kiefer (1999) referem como intervalo para a avaliação da

²³ J.A. Richards, 2006, “Remote Sensing Digital Image Analysis, Springer-Verlag”, Berlin, p. 268.

²⁴ Matriz de variâncias-covariâncias – medida estatística de dispersão de variáveis aleatórias em torno seu centróide. A diagonal principal representa as variâncias (dispersão das variáveis em torno do seu valor médio) e o resto dos valores da matriz representam as covariâncias (dispersão das variáveis aleatórias num espaço de n-dimensões, i.e, medida que representa a variabilidade conjunta de duas ou mais variáveis aleatórias).

²⁵ Distribuição normal – uma distribuição da estatística descrita pelos parâmetros de média e desvio padrão. Também chamada de distribuição Gaussiana, serve de aproximação para o cálculo de probabilidades de outras distribuições quando estas são demasiado grandes.

separabilidade os valores 0 e 2000, sendo que valores abaixo dos 1500 denotam semelhanças entre classes.

- Classificação das parcelas de treino:

Outra estratégia para a avaliação da representatividade espectral das parcelas de treino passa por classificar somente as parcelas de treino comparando os resultados com os esperados através de uma matriz de confusão ou matriz de erro.

- Classificação interactiva:

Os programas de processamento de imagem, como o ENVI, incluem no processo de classificação a opção de efectuar uma classificação preliminar interactiva de modo a ilustrar o resultado obtido com determinadas parcelas de treino e inferir sobre a representatividade das mesmas na imagem. Contudo, este método deverá ser utilizado com classificadores computacionalmente mais eficientes de modo a não tornar pesada a classificação preliminar.

- Classificação de uma fracção representativa da imagem:

O operador pode optar por classificar uma área que considere ser representativa da área total. Este processo pode ser iterativo comparando os resultados com dados de referência através de uma matriz de confusão.

A selecção de parcelas de treino é por si só um processo lento. Implica uma acção iterativa de escolha e análise da informação estatística das parcelas de treino com o objectivo de chegar a um patamar de separabilidade espectral suficiente para garantir resultados satisfatórios na classificação.

No segundo passo o operador indica ao classificador as parcelas de treino seleccionadas, representativas das classes a classificar. Os resultados dependerão naturalmente da qualidade das parcelas de teste e da natureza do classificador. Mais à frente iremos descrever de forma sucinta o funcionamento dos classificadores supervisionados disponíveis no software ENVI.

Por último, e depois de terminada a classificação, o operador terá que avaliar a exactidão dos resultados (passo 3) para garantir a qualidade dos mesmos. Para isso, é

necessário comparar quantitativamente os resultados obtidos com uma referência ou “verdade de campo”, para isso, é elaborado um mapa classificado manualmente com as classes definidas. Os métodos de análise mais utilizados para a avaliação de resultados são a matriz de confusão, que compara as classes classificadas com o mapa de referência, e o índice de concordância Kappa. Mais à frente nesta tese descreveremos o funcionamento destas duas medidas de avaliação de resultados.

Como já referimos anteriormente, o objecto de estudo desta tese centrou-se no estudo de *performance* de classificadores supervisionados *pixel a pixel*. Estes podem-se dividir em dois grupos, conforme a natureza dos algoritmos. São ele os paramétricos, que assumem que as assinaturas espectrais das parcelas de treino têm uma natureza Gaussiana, i.e, uma distribuição normal e os não-paramétricos que não utilizam esta distribuição estatística. De entre os classificadores estudados são paramétricos a máxima verosimilhança, distância Mahalanobis, e não paramétricos, o algoritmo do paralelepípedo, da mínima distância, do mapeamento de ângulos espectrais (MAE) e da codificação binária. A escolha particular destes seis classificadores deve-se ao facto de serem os classificadores disponíveis no software ENVI, software que utilizámos para o processamento da imagem.

II.3.2.1 Paralelepípedo

O classificador paralelepípedo actua com base na informação dos histogramas dos componentes espectrais das parcelas de treino (Figura 8). Este classificador identifica os valores espectrais mínimo e máximo das parcelas de treino para cada uma das bandas. De seguida constrói gráficos de dispersão n-dimensionais (número de bandas), envolvendo as assinaturas espectrais das parcelas de treino em rectângulos (Figura 9). É com base na representação espacial desses rectângulos que o algoritmo faz a classificação. Se determinados pixéis ficam dentro de um rectângulo estes são classificados como pertencentes à classe cujo rectângulo representa.

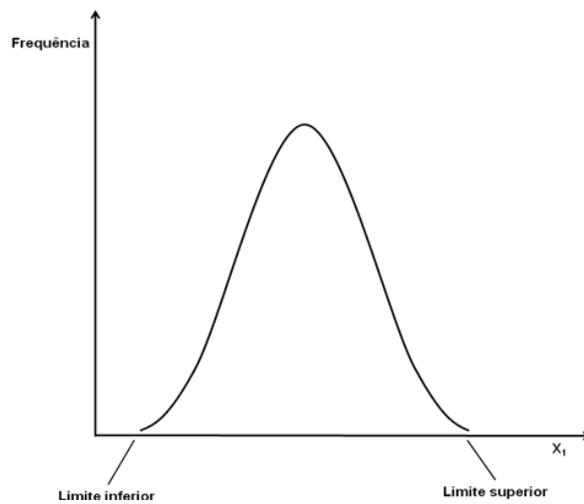


Figura 8 - Histograma para os componentes bi-dimensionais da informação espectral de uma parcela de treino.

Fonte: Richards e Jia (2006) (adapt.)

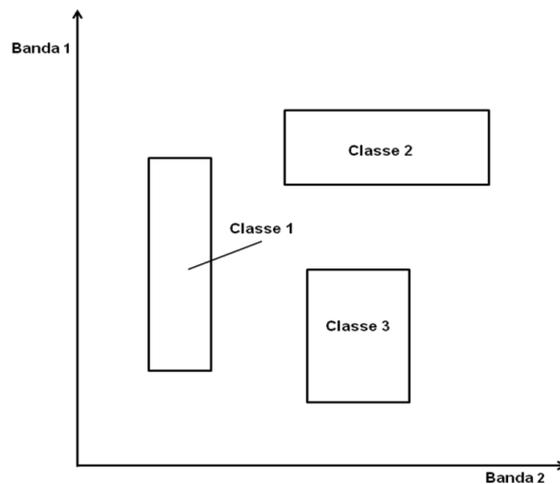


Figura 9 - Exemplo de retângulos representativos de classes num gráfico bi-dimensional de duas bandas.

Fonte: Richards e Jia (2006) (adapt.)

Apesar de este classificador ser simples e computacionalmente eficiente, tem algumas desvantagens. Por exemplo, o algoritmo não consegue classificar pixéis que não pertençam a nenhum dos retângulos de classes. Por outro lado, não tem em conta

as probabilidades *a priori* dos pixels pertencerem a determinada classe, e por último em casos onde exista uma sobreposição de retângulos²⁶, o algoritmo poderá não conseguir à partida separar os pixels que pertencem a essas sobreposição (Figura 10).

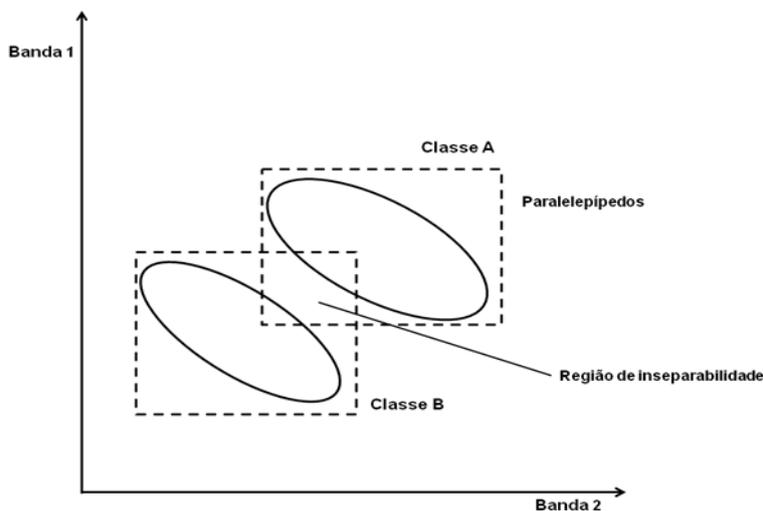


Figura 10 - Exemplo de inseparabilidade resultante do classificador paralelepípedo.

Fonte: Richards e Jia (2006) (adapt.)

II.3.2.2 Máxima Verossimilhança

O classificador de máxima verossimilhança é um dos algoritmos mais utilizados no processamento de imagens de satélite. Apesar de não ser computacionalmente tão eficiente como o algoritmo do paralelepípedo, é um dos classificadores que apresenta melhores resultados.

O algoritmo assume que as assinaturas espectrais das parcelas de treino de cada classe apresentam uma distribuição Gaussiana (Figura 11). Para isso, avalia a média, variâncias e co-variâncias das parcelas de treino, para assim determinar a distribuição Gaussiana de cada uma delas. Esta distribuição é traduzida pela função de densidade de probabilidade²⁷ com base no teorema de Bayes²⁸. É com esta função que o algoritmo

²⁶ O *ENVI* neste caso classifica o pixel com a última classe no qual pertence. Contudo, esta opção não elimina por completo as possíveis classificações erradas.

²⁷ Funções utilizadas para traduzir distribuições de probabilidade, caso as variáveis aleatórias sejam contínuas.

classifica os pixéis como tendo maior ou menor probabilidade de pertencer a uma determinada classe. Num caso bi-dimensional o gráfico de dispersão simplifica as assinaturas espectrais das parcelas de treino transformando-as em formas elípticas. Estas por sua vez são associadas a funções de densidade de probabilidade, que servem de base à classificação pelo algoritmo dos pixéis consoante se encontrem numa zona de maior ou menor probabilidade de pertença a uma determinada classe (gráfico superior da Figura 11).

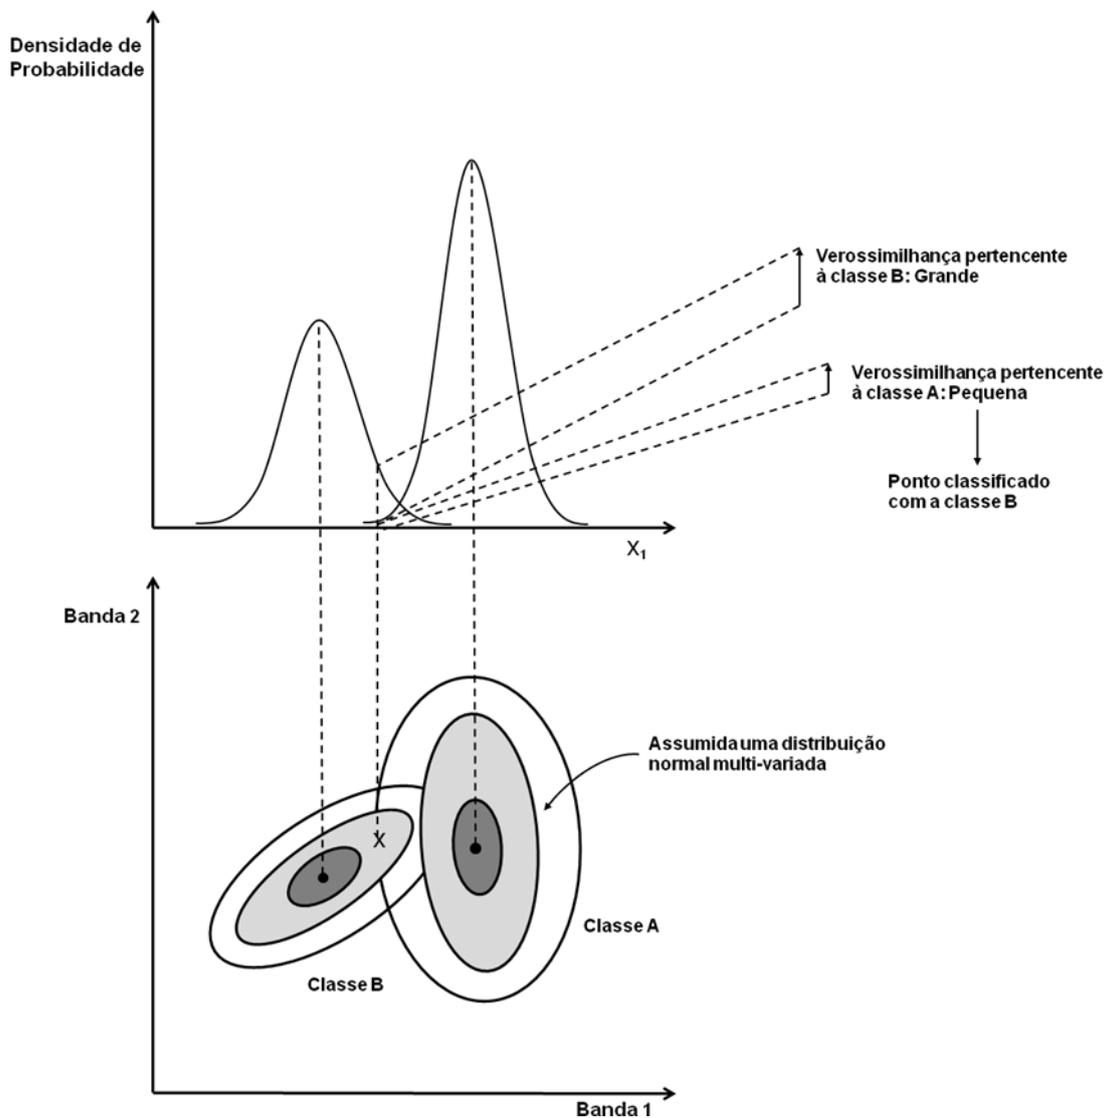


Figura 11 - Princípio do classificador de máxima verossimilhança.

Fonte: <http://www.dgeo.udec.cl/yuras/tutoriales/rsnote/cp11/cp11-7.htm> (16/02/2011)

²⁸ Teorema de Bayes diz que a probabilidade de um evento A acontecer dado um evento B depende não só da relação entre os eventos A e B mas também da probabilidade de ocorrência de cada um dos eventos.

O classificador de máxima verosimilhança tem a grande vantagem de utilizar métodos probabilísticos para a classificação de imagens. Contudo, a classificação pode ficar comprometida se não existirem pixels suficientes nas parcelas de treino que permitam valores significativos de médias, variâncias e co-variâncias²⁹. A classificação também pode ser prejudicada se existir um grau elevado de correlação entre bandas, ou se as classes não tiverem um comportamento de uma distribuição Gaussiana.

II.3.2.3 Mínima Distância às médias espectrais

O classificador de mínimas distâncias é um algoritmo simples e rápido. Não depende do número de pixels seleccionado para cada parcela de treino (como o de máxima verosimilhança), pois precisa somente de calcular as médias associadas a cada parcela de treino.

Cada parcela de treino é representada num gráfico de dispersão n-dimensional como uma nuvem de pixels. O algoritmo calcula para cada uma das parcelas de treino, uma média que representa o centro geométrico desse conjunto de pixels a que se dá o nome de centróide³⁰. Posteriormente calcula a distância Euclidiana³¹ entre todos os pixels da imagem e os centróides das parcelas de treino, classificando o pixel com a classe que corresponder à menor distância calculada.

Apesar de muito rápido, o classificador baseia-se apenas na informação espectral das parcelas de treino. Dado não ter em conta as co-variâncias das parcelas de treino, este classificador trata essas amostras, no seu domínio espectral, como simétricas, i.e, não tem em consideração, por exemplo, uma amostra espectralmente alongada (Figura 13).

²⁹ Medida estatística que indica a correlação entre duas variáveis aleatórias.

³⁰ Centróide é, por definição, o ponto dentro de uma figura que define o seu centro geométrico. Pode-se considerar, de um modo simples, como a média dos pontos pertencentes à figura.

³¹ Distância entre dois pontos definida como: $\sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}$

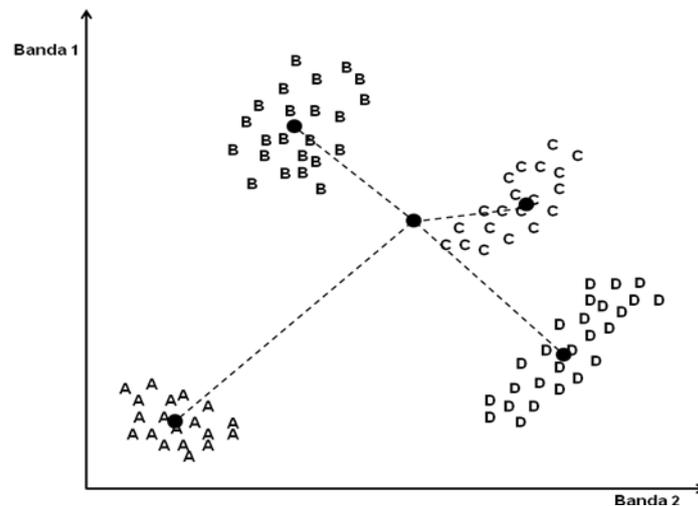


Figura 12 – Exemplo das distâncias de um pixel aos centróides de várias parcelas de treino.

Fonte: Richards e Jia (2006) (adapt.)

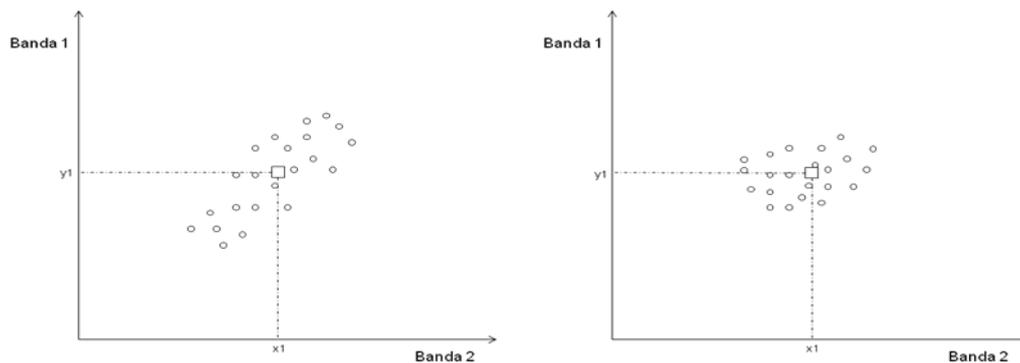


Figura 13 – Exemplo de duas amostras espectrais com o mesmo centróide mas com diferentes dispersões.

Fonte: do autor

II.3.2.4 Distância de Mahalanobis

O classificador de distância de Mahalanobis tem por base o classificador de mínima distância, mas ao contrário deste, que considera que existe uma simetria na representação espectral das parcelas de treino num gráfico de dispersão, i.e, que não existe variabilidade nas parcelas de treino nas n-dimensões da imagem (Figura 13), a distância de Mahalanobis incorpora na distância Euclidiana a dispersão das parcelas de treino no espaço n-dimensional da imagem, i.e., tem em conta a forma da nuvem de

pixéis das parcelas de treino (Figura 14), na forma de matrizes de variância-covariância, conseguindo assim considerar a orientação e dispersão dos dados.

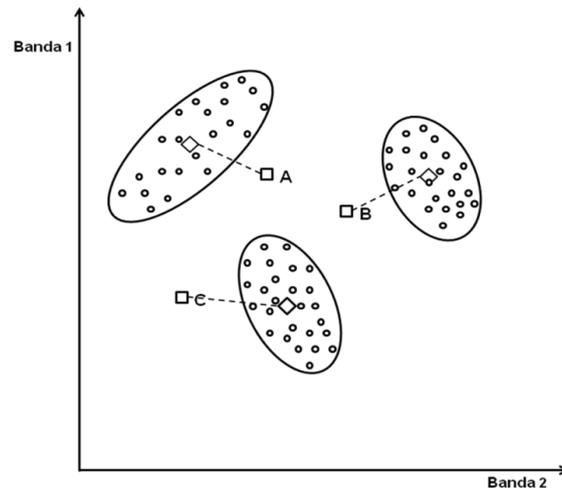


Figura 14 – Princípio do classificador distância de Mahalanobis.

Fonte: do autor

II.3.2.5 Mapeamento de ângulo espectral

A natureza geométrica dos pixéis no espaço n-dimensional de uma imagem pode ser descrita de duas maneiras: segundo o seu comprimento vectorial e/ou segundo o ângulo medido entre um dos eixos do sistema de coordenadas do espaço n-dimensional e o vector definido pelo ponto de origem do sistema de coordenadas e o pixel (Figura 15). Este classificador baseia-se na informação angular atrás referida para classificar a imagem. De facto, o valor espectral pode variar entre pixéis pertencentes a uma mesma classe, mas a sua informação angular permanece constante. A condição para a classificação tem por base a informação angular dos pixéis, i.e., o ângulo espectral do pixel a classificar é comparado com os ângulos espectrais que discriminam as parcelas de treino (ângulos de fronteira entre parcelas de treino) e classificado conforme o seu ângulo seja maior ou menor que esses ângulos espectrais fronteiros (Figura 15).

Este tipo de algoritmo dará bons resultados se as classes estiverem suficientemente dispersas pelo espaço n-dimensional da imagem, i.e., que permitam a identificação de ângulos de fronteira entre classes, independentemente dos valores espectrais que tenham.

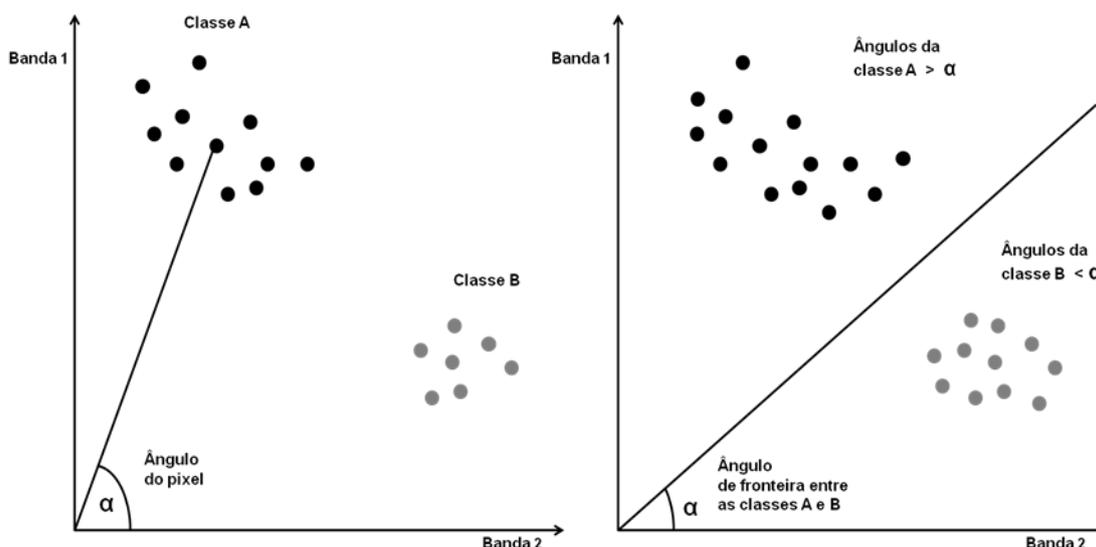


Figura 15 - À esquerda dois elementos com o mesmo ângulo e magnitudes diferentes.

À direita elementos com ângulos diferentes e magnitudes diferentes.

Fonte: <http://wgbis.ces.iisc.ernet.in/energy/paper/TR-111/chapter3.htm>

II.3.2.6 Codificação Binária

O algoritmo de codificação binária atribui a todos os pixels da imagem e de cada parcela de treino, o valor “0” ou “1” conforme o valor esteja acima ou abaixo de uma média espectral da imagem e de cada parcela de treino consideradas. De seguida, classifica a imagem efectuando uma operação de “OU exclusivo”³² entre a imagem e as parcelas de treino.

Apesar de computacionalmente eficiente, este tipo de algoritmo não apresenta resultados satisfatórios, pois converte a riqueza espectral de uma imagem multiespectral em “0” e “1”, i.e., perde-se muito do pormenor espectral da imagem na codificação binária da imagem.

³² Do inglês “exclusive OR” (ver em anexo 2)

II.4 Ferramentas de avaliação de exactidão de resultados

O processo de classificação não está concluído sem que se faça uma avaliação temática dos resultados que permita ao utilizador conhecer o nível de confiança da classificação, comparando-o para isso com um mapa de referência que traduza com rigor as classes que caracterizam a imagem. Este mapa poderá resultar de uma observação *in situ* ou mais comumente através de fotointerpretação. Os dois métodos de avaliação de exactidão temática mais utilizados são: a matriz de confusão e o índice de concordância Kappa, dos quais iremos de seguida apresentar o *modus operandi*.

II.4.1 Matriz de confusão

A matriz de confusão (Tabela 12) apresenta-se em forma de tabela de dupla entrada e permite confrontar o número de pixéis classificados com o número de pixéis de referência para cada uma das classes. A matriz de confusão é uma matriz quadrada, i.e., tem igual número de colunas e linhas, na sua diagonal principal estão representados o número de pixéis bem classificados, os elementos não-diagonais representam o número de pixéis classificados erradamente, por omissão ou comissão noutras classes.

		Referência				Comissão	Exactidão do produtor
		Classe A	Classe B	Classe C	Total		
Resultado	Classe A	25	6	3	34	26.5%	73.5%
	Classe B	2	39	2	43	9.3%	90.7%
	Classe C	5	1	45	51	11.8%	88.2%
Total		32	46	50	128		
Omissão		21.9%	15.2%	10.0%		85.2%	Exactidão Global
Exactidão do utilizador		78.1%	84.8%	90.0%			

Tabela 12- Exemplo de uma matriz de confusão³³. Fonte: do autor

³³ As operações para calcular as percentagens podem encontrar-se em anexo.

A matriz de confusão foi tradicionalmente usada como uma avaliação global dos resultados. Contudo, reduzir esta ferramenta a uma medida global de exactidão será redutor, uma vez que não é garantido que uma exactidão global alta traduzirá bons resultados em cada uma das classes. Assim, no estudo da matriz de confusão o utilizador terá que ter em conta não só a exactidão global, mas também a exactidão de cada uma das classes, comparando-as com as classes de referência.

Para além da exactidão global da classificação (somatório dos pixéis bem classificados sobre o número total de pixéis), pode-se ainda calcular as exactidões correspondentes a cada uma das classes. Essas exactidões podem-se apresentar sob duas perspectivas: a exactidão do produtor e a exactidão do utilizador, e calculam-se dividindo o número de pixéis correctamente classificados pelo número total de pixéis classificados nessa classe.

A exactidão do utilizador indica a percentagem de pixéis em cada uma das classes que foram correctamente classificados, quando comparados com as classes de referência. Existe, por contraponto o erro de omissão que traduz a percentagem dos pixéis que foram classificados erradamente noutras classes.

A exactidão do produtor, por sua vez, dá-nos a percentagem de pixéis correctamente classificados, comparando com as classes resultantes da classificação. O erro associado a esta medida é o erro de comissão, que indica a percentagem de pixéis classificados que deveriam ter sido classificados noutras classes.

II.4.2 Índice de concordância Kappa

A matriz de confusão é por si só uma medida apropriada na avaliação da exactidão de classificações. No entanto, não considera para a avaliação global o peso das exactidões individuais de cada uma das classes. O índice de concordância Kappa, ou simplesmente índice Kappa, avalia se a concordância entre os mapas é melhor do que numa classificação aleatória, i.e., mede a diferença entre os pixéis bem classificados e as omissões ou comissões dos pixéis na classificação de uma mesma classe. Neste sentido, é uma medida de avaliação da exactidão global mais rigorosa, pois tem em conta toda a informação existente numa matriz e não só a diagonal principal como a matriz de confusão.

O índice Kappa é calculado da seguinte maneira:

$$K = \frac{n \sum_{i=1}^p x_{ii} - \sum_{i=1}^p x_{io} x_{oi}}{n^2 - \sum_{i=1}^p x_{io} x_{oi}}$$

Onde,

n = número total de pixels

p = número de classes

$\sum x_{ii}$ = somatório dos elementos da diagonal da matriz de confusão

$\sum x_{io}$ = somatório dos elementos da linha i

$\sum x_{oi}$ = somatório dos elementos da coluna i

O índice Kappa é portanto uma medida que avalia o grau de concordância entre a imagem classificada e o mapa de referência. O índice Kappa pode ter valores entre -1.0 e 1.0. Um índice Kappa maior que 0 indica algum grau de concordância entre os valores e 1 indica uma concordância perfeita. Na Tabela 13 podemos ver a escala empírica proposta por Landis e Koch (1997) para o índice onde fazem correspondem a intervalos de Kappa, índices de concordância.

Valores de Kappa	Níveis de concordância
< 0	Ausente
]0.0, 0.20[Baixo
[0.20, 0.40[Razoável
[0.40, 0.60[Moderado
[0.60, 0.80[Substancial
[0.80, 1.00[Quase perfeito
= 1	Perfeito

Tabela 13 - Medidas de concordância do índice Kappa.

Fonte: Landis e Koch “The measurement of observer agreement for categorical data”, Biometrics 1997” (adapt.)

Estes dois tipos de avaliação da exactidão de uma classificação dão-nos uma avaliação quantitativa do erro na classificação, resultado da comparação da imagem classificada com o mapa de referência, permitindo assim conhecer o grau de confiança nas classificações efectuadas.

Capítulo III: Experimentação de classificadores sobre imagens QuickBird

III.1 Dados e Área de estudo

Como já referimos anteriormente neste estudo utilizámos uma imagem do satélite *QuickBird*. Este satélite adquire cenas com 16.5 por 16.5 km e opera nos modos pancromático com uma resolução espacial de cerca de 0.6 m e multiespectral nas bandas do visível e do infravermelho próximo com uma resolução espacial de cerca de 2.4 m. Sendo um satélite de alta resolução espacial com uma vertente nomeadamente comercial a sua aplicação vai desde a agricultura, à monitorização de florestas ou ao estudo de alterações de ocupação e uso do solo, entre outras.

Neste estudo trabalhámos sobre uma imagem *QuickBird* (Tabela 3) adquirida a 14 de Abril de 2005 com um ângulo em nadir de 12.2°. Esta imagem foi alvo de uma fusão entre as bandas pancromáticas e as multiespectrais resultando num refinamento da imagem para um tamanho de pixel de 0.6m e de uma ortorectificação (Freire *et al.*, 2010). A imagem incide sobre uma das áreas de estudo do projecto GeoSat, no qual esta tese é desenvolvida, com o intuito de comparar os resultados obtidos.

A zona em estudo ocupa uma parte nordeste da cidade de Lisboa (Figura 1) numa área de cerca de 64ha (800x800m). É caracterizada por zonas habitacionais, vegetação (árvores, relva e vegetação rasteira), zonas agrícolas, solo a descoberto, zonas industriais, estradas, etc. (Freire *et al.*, 2010).

III.2 Metodologia

III.2.1 Nomenclatura proposta

A nomenclatura seguida neste trabalho tem por base a realidade urbana da zona abrangida pela imagem já anteriormente descrita. Adoptou-se uma nomenclatura organizada num esquema de níveis hierárquicos partindo do mais geral para o mais específico (Kux *et al.*, 2006 e Heiden *et al.*, 2007). Conjugando as classes que mais se destacam e tendo em conta o nível discriminante que a imagem permite, organizámos um esquema hierárquico dividido em quatro níveis (Figura 16). No primeiro nível

dividimos a imagem em duas classes, sombra e não-sombra, no sentido de minimizar os efeitos negativos que a classe sombra exerce na classificação da imagem (Carleer e Wolff, 2006), descartando-a daí para a frente do processo de classificação. Na estratégia seguida a classe sombra não é considerada para os níveis seguintes, dada a dificuldade que existe em classificar este tipo de classe, facto que sai do âmbito de estudo desta tese. No segundo nível a divisão da classe não-sombra resulta em duas outras classes mais gerais que separam a vegetação da não-vegetação. O terceiro nível segue as classes: vegetação, subdividida nas classes, árvores, relva e vegetação herbácea; e não-vegetação subdividida nas classes, solo nu, solo agrícola, telhados e pavimentos. No quarto e último nível a classe árvores subdivide-se em árvores claras e escuras, a classe telhados subdivide-se em telha laranja e telhados claros, médios e escuros e por último a classe pavimentos subdivide-se em pavimentos claros e escuros.

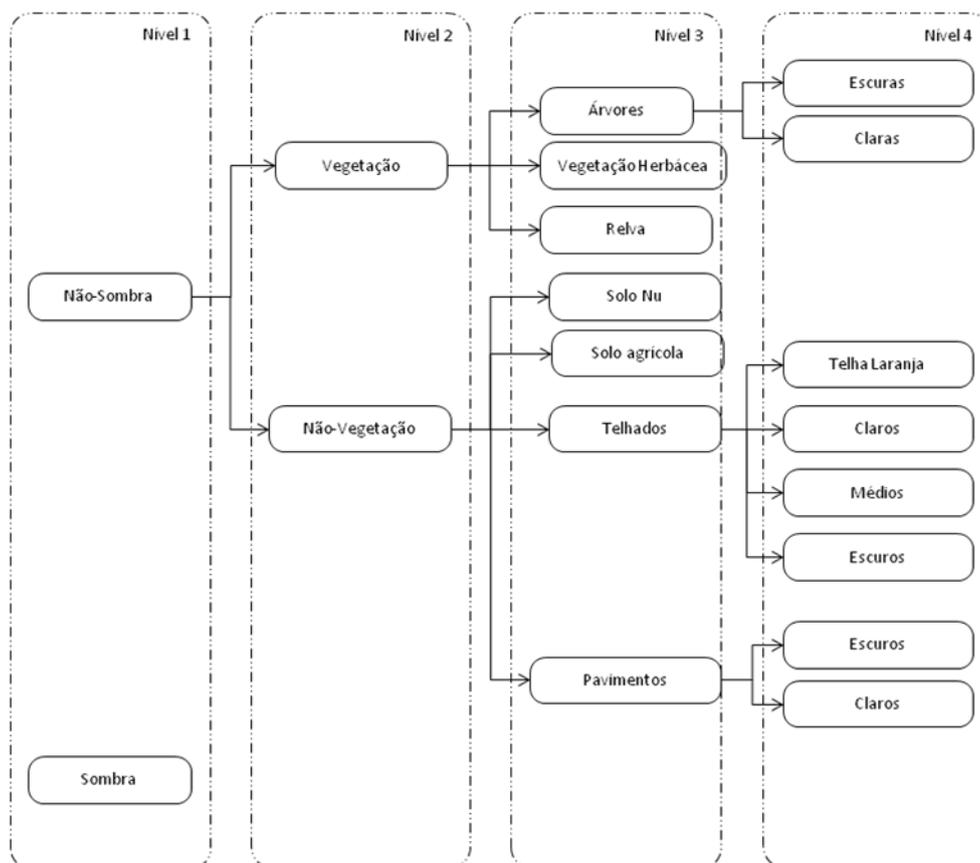


Figura 16 - Hierarquia de classes (nomenclatura proposta para a zona abrangida pela imagem QuickBird)

III.2.2 Processos de classificação propostos

Com a hierarquização por níveis das classes definidas anteriormente, procurámos, no processo de classificação, refinar a exactidão temática das doze classes mais discriminantes (Tabela 14), as quais considerámos como sendo, no pormenor geométrico que a imagem permite, as mais caracterizadoras da zona. Como anteriormente referimos a classe Sombra foi descartada desta selecção. Este facto prende-se com a possibilidade de esta classe introduzir erros na classificação os quais seriam difíceis de tratar dada a sua natureza espectral (Carleer e Wolff, 2006). Considerámos portanto, que estudo em pormenor desta classe sairia assim fora do âmbito de esta tese.

Para estudar a exactidão das classes da Tabela 14 no processo de classificação, traduzimos num fluxograma um conjunto de regras aplicadas a cada nível (Figura 18), para assim conseguirmos extrair os melhores resultados consequentes da aplicação dos classificadores em estudo às classes de cada nível.

Nível	Classes
Nível III – Vegetação	Relva
	Vegetação Herbácea
Nível III – Não Vegetação	Solo Nu
	Solo Agrícola
Nível IV – Árvores	Árvores Claras
	Árvores Escuras
Nível IV – Telhados	Telhados Claros
	Telhados Médios
	Telhados Telha Laranja
	Telhados Escuros
Nível IV – Pavimentos	Pavimentos Claros
	Pavimentos Escuros

Tabela 14 – Nomenclatura final com as classes mais discriminantes da zona de estudo

As classes dos níveis desempenharam um papel segmentador actuando como máscaras, permitindo assim minimizar as classificações erróneas das classes dos níveis subsequentes, e.g., no primeiro nível separou-se a Sombra da Não-Sombra para no nível seguinte usar a classe Não-Sombra para classificar as classes vegetação e Não-

Vegetação, no terceiro nível as classes Relva, Vegetação Herbácea e Árvores foram classificadas usando somente a classe Vegetação, procedendo no mesmo sentido com as restantes classes.

O processo de classificação (Tabela 15) implicou ainda o recurso à noção de nível temático, uma vez que, sendo todos os níveis referentes a um tema geral, foi necessário subdividir os níveis III e IV de acordo com a classe mãe considerada. Assim, o nível III divide-se em duas classes mãe (Vegetação e Não-Vegetação) que são objecto de classificação separada; e o nível IV subdivide-se em três classes mãe (Árvores; Telhados e Pavimentos), que são também alvo de classificação posterior.

Processamento	Níveis	Classes-mãe	Classes a classificar
1	Nível 1	N/A	Sombra, Não-sombra
2	Nível 2	Não-sombra	Vegetação, Não-Vegetação
3	Nível 3	Vegetação	Árvores, Vegetação-Herbácea, e Relva
4		Não-Vegetação	Solo-Nu, Solo-Agrícola, Telhados, e Pavimentos
5	Nível 4	Árvores	Árvores Claras e escuras
6		Telhados	Telhados Claros, médios, telha laranja, Escuros
7		Pavimentos	Pavimentos claros e escuros

Tabela 15 – Ordem do processo de classificação

Propusemos ainda para experimentação dois tipos de abordagem no processo de classificação: uma primeira, a que chamámos “processo de classificação por níveis”, onde avaliámos a exactidão global dos níveis temáticos (ou classes mãe). Nesta abordagem, foram experimentados em cada nível classificadores diferentes e seleccionadas as classificações com a melhor exactidão global. Utilizámos depois as classes do nível como máscaras para a classificação das classes dos níveis subsequentes, procedendo deste modo até ao último nível.

A segunda abordagem utilizada, que designámos por “processo de classificação por classes” utiliza como unidade de análise a própria classe. Assim, a escolha centra-se agora, não na melhor exactidão global do nível, mas na melhor exactidão do utilizador referente a cada classe. Procurámos assim, identificar as classes com os melhores resultados, podendo estas pertencer a classificações diferentes. As classes seleccionadas

foram posteriormente usadas como máscaras para classificar as classes dos níveis seguintes.

Como dados de entrada deste processo, para além da óbvia imagem de satélite, elaborámos mapas de referência³⁴ que constituíram o nosso modelo da realidade, para cada um dos níveis da hierarquia de classes, e também um mapa de referência com as classes mais discriminantes atrás enunciadas (Figura 17). Os mapas foram construídos com o auxílio do software ArcGIS para cada um dos níveis, pela identificação visual, com base na imagem, das classes de todos os níveis. Procurámos acompanhar a normal interpretação visual com informação proveniente de outros mapas (e.g., Google maps) e com saídas de campo sempre que alguma área da imagem nos suscitava dúvidas.

Já referimos anteriormente que centrámos esta tese no estudo de *performance* de classificadores supervisionados *pixel a pixel*. O primeiro passo na utilização deste tipo de classificadores é proceder à recolha de amostras de áreas que caracterizem cada uma das classes nos diferentes níveis, i.e., amostras espectralmente representativas das classes. Essas amostras, chamadas de parcelas de treino, permitem fornecer aos classificadores dados para a criação de assinaturas espectrais para cada classe para o processo algorítmico característico de cada classificador. A escolha rigorosa das parcelas de treino no processo de classificação assumem maior relevância por inferir directamente na qualidade do resultado das classificações, pelo que utilizámos vários métodos para refinar a qualidade das mesmas, nomeadamente medidas estatísticas (médias, variâncias, etc.), gráficos espectrais, e estudos de separabilidade espectral.

³⁴ Em anexo encontram-se os mapas de referência elaborados para cada um dos níveis.



0 100 200 m



Figura 17 - Mapa de referência para as classes mais discriminantes

As duas abordagens têm como ponto de partida comum a imagem de satélite, a hierarquia de classes, e o mapa de referência com as classes para cada nível temático, mas divergem no objecto de avaliação dos resultados.

Assim, o processo de classificação por níveis foi concretizado de uma forma algorítmica seguindo o fluxograma estabelecido (Figura 18) e, como referido anteriormente, circunscreve a avaliação e tomada de decisão ao nível temático. O processo de processamento segue a ordem de processamento da Tabela 15 e compõe-se nos seguintes passos:

1. Recolher parcelas de treino para as classes a classificar do nível em análise;
2. Se for o primeiro nível, passar para o passo 3, se não, aplicar à imagem a máscara da classe mãe do nível em análise (classe pertencente ao nível anterior melhor classificado);
3. Classificar as classes do nível em análise com os 6 classificadores;
4. Calcular a matriz de confusão e índice Kappa entre o mapa de referência e cada uma das classes classificadas para o nível em análise;
5. Para o nível em análise identificar a classificação que apresenta a melhor exactidão global e um índice de concordância Kappa igual ou superior a Razoável para aplicar no nível seguinte como máscara;
6. Se for o último processamento terminar, se não, continuar voltando ao passo 1.

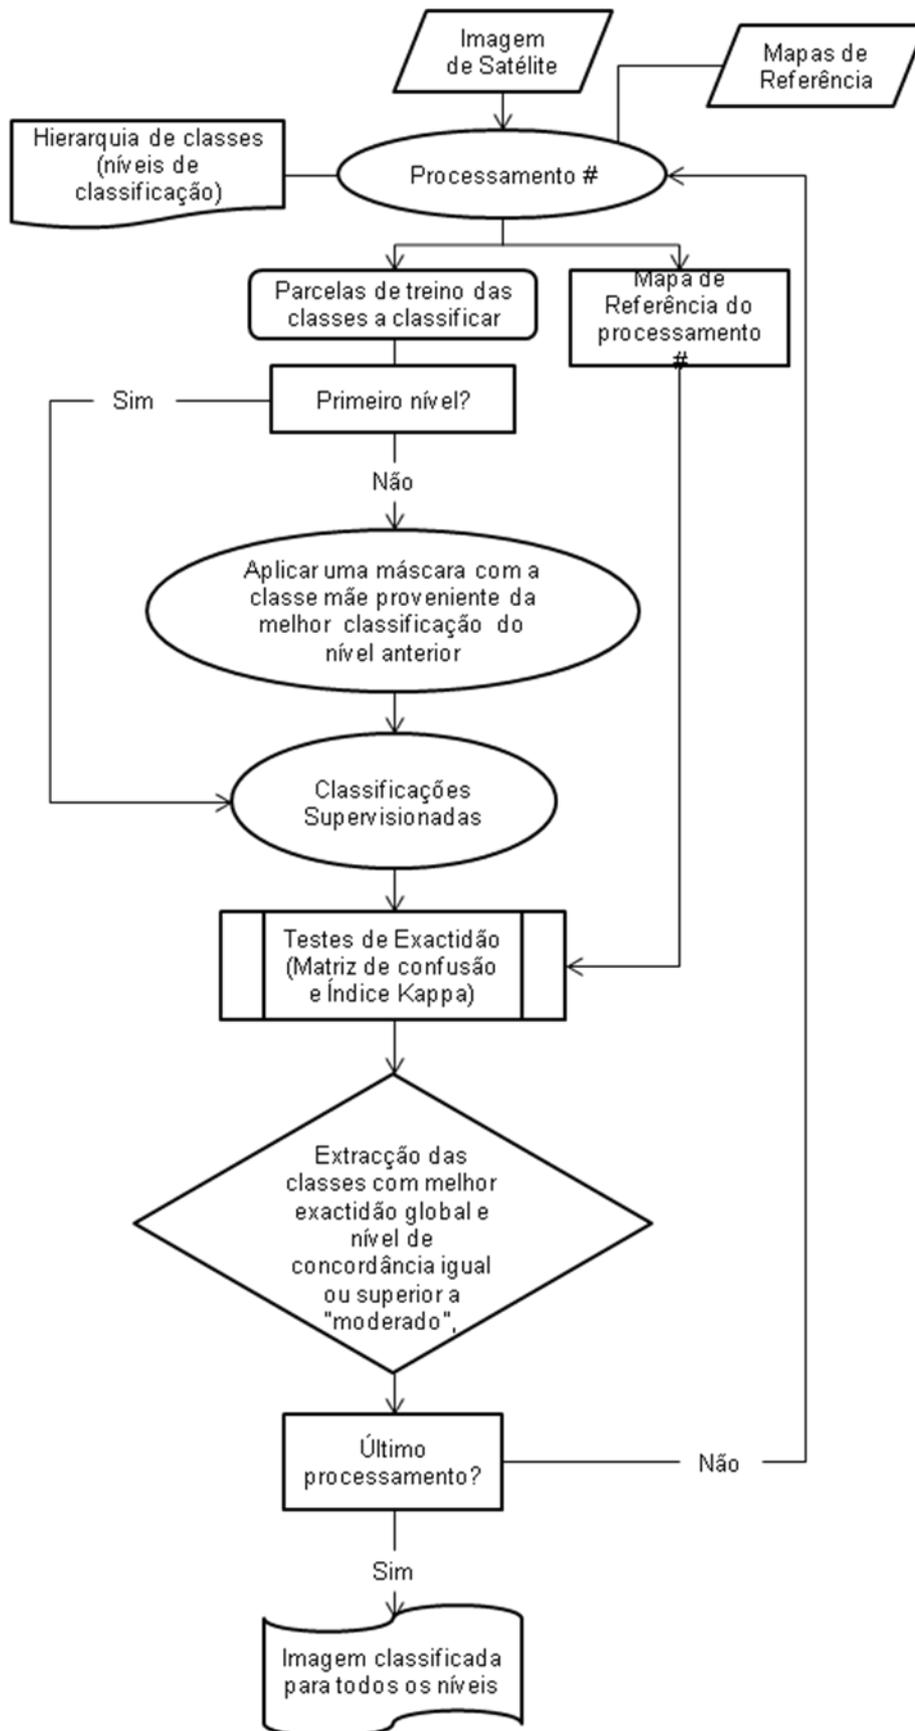


Figura 18- Fluxograma do processo de classificação por níveis

Na segunda abordagem – “processo de classificação por classes” (cujo fluxograma apresentamos na Figura 19) – quisemos ainda estudar as consequências de uma classificação feita com extração das classes com a melhor exactidão do utilizador, independentemente de pertencerem, ou não, ao mesmo nível temático. Tendo os mesmos dados de entrada da abordagem anterior e a mesma ordem de processamento (Tabela 15), procedemos do seguinte modo:

1. Recolher parcelas de treino para as classes a classificar do nível em análise;
2. Se for o primeiro nível, passar para o passo 3, se não, aplicar à imagem a máscara da classe mãe melhor classificada (com a melhor exactidão do utilizador);
3. Classificar as classes do nível em análise com os 6 classificadores;
4. Calcular a matriz de confusão e índice Kappa entre o mapa de referência e cada uma das classes classificadas para o nível em análise;
5. Para o nível em análise identificar as classificações das classes que apresentam a melhor exactidão do utilizador e um índice de concordância Kappa igual ou superior a Razoável para serem utilizadas como máscaras no passo 2;
6. Se for o último processamento terminar, se não, continuar voltando no passo 1.

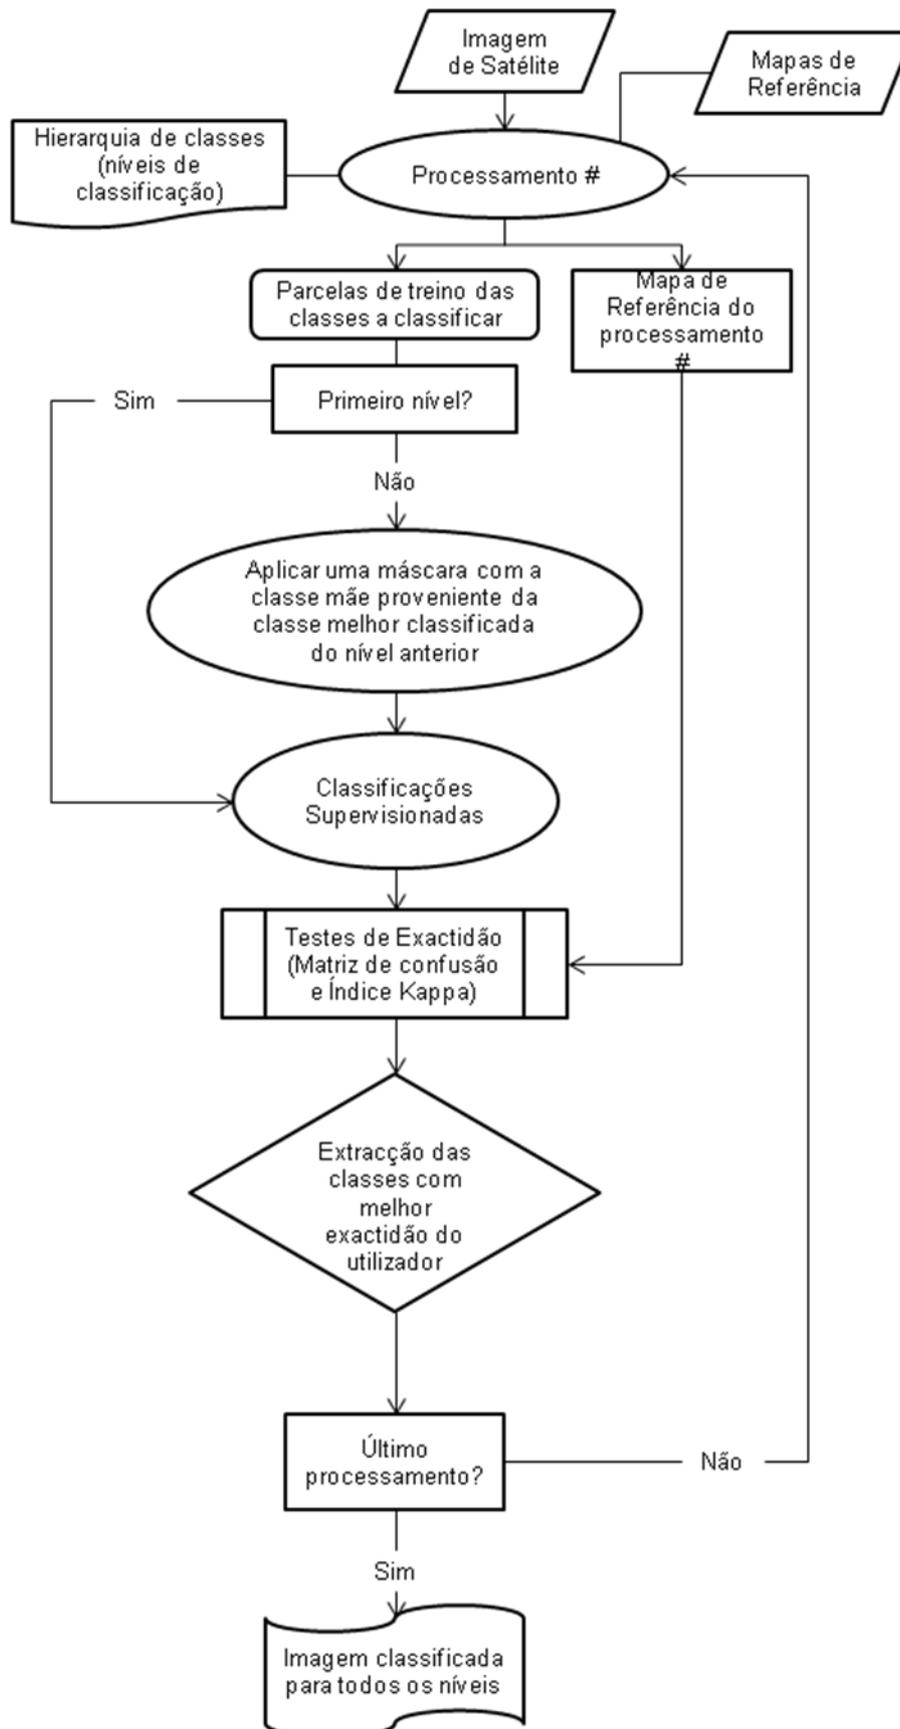


Figura 19 - Fluxograma do processo de classificação por classes

Capítulo IV: Resultados e discussão

A utilização de imagens de alta resolução na classificação em meio urbano não significa necessariamente melhores resultados. Apesar do maior detalhe espacial da imagem, com a presença de pixéis mais puros e a diminuição de pixéis mistos, o que levaria a um aumento da exactidão da classificação, o facto de existir maior detalhe espacial aumenta a variância espectral dentro das classes, diminuindo em contrapartida a separabilidade entre as mesmas, podendo assim, resultar numa diminuição de exactidão na classificação no caso de classificações ao nível do pixel. Procurámos, com as abordagens seguidas, minimizar esse efeito nefasto, nomeadamente com a utilização de classificadores ao nível do pixel numa abordagem hierárquica de classes, utilizando as classes classificadas como máscaras aplicando-as ao longo da classificação das classes de cada nível. Apresentaremos de seguida os resultados que obtivemos, aplicando os processos de classificação expostos no capítulo anterior, acompanhados de uma visão crítica dos mesmos.

IV.1 Processo de classificação por níveis

Para a avaliação dos resultados de ambas as abordagens seguidas, construímos as respectivas matrizes de confusão em cada um dos níveis. Considerámos para o efeito somente os resultados de classificações que tinham correspondência directa com as classes de referência, condição necessária para a construção de uma matriz de confusão³⁵, e também só considerámos as classificações com um índice de concordância Kappa igual ou superior a “Razoável”³⁶, pois consideramos que será um limiar de concordância mínimo para garantirmos alguma confiança nos resultados.

Em cada uma das abordagens propostas foram classificados cada um dos níveis pelos seis classificadores supervisionados *pixel a pixel* disponíveis no software ENVI. No processo de classificação por níveis (Figura 18) as classes de cada nível resultantes

³⁵ Como já anteriormente referido a matriz de confusão é uma matriz quadrada.

³⁶ Ver capítulo II.4.2, Tabela 13 - Medidas de concordância do índice Kappa. Fonte: Landis e Koch “The measurement of observer agreement for categorical data”, Biometrics 1997” (adapt.)

da classificação com a melhor exactidão global, foram utilizadas como máscaras e aplicadas na classificação do nível seguinte. No processo de classificação por classes (Figura 19) foram seleccionadas as classes resultantes da classificação com as melhores exactidões do utilizador para servirem de máscaras para as classes do nível seguinte. Em cada uma das abordagens foram avaliados os resultados através da construção de matrizes de confusão. A avaliação incidiu, sobre a Exactidão Global (EG) das classificações no caso do processo de classificação por níveis, e sobre a exactidão do utilizador (EU) para cada uma das classes de cada um dos níveis no caso do processo de classificação por classes.

A Tabela 16 mostra as exactidões globais resultantes da avaliação das classificações por níveis temáticos (Tabela 15) efectuadas por cada um dos classificadores aplicados a cada um dos níveis da hierarquia de classes seguida (Figura 16). Destacámos para cada nível a maior EG conseguida por um classificador, bem com os respectivos índices Kappa (IK). Alguns classificadores não conseguiram classificar algumas classes pelo que não foram considerados para a avaliação dos resultados. Todos os casos foram assinalados com "--" nas tabelas das exactidões de resultados.

A análise revelou a existência de resultados de EG bastante satisfatórios: entre 80% e 90% de EG nos níveis I, II, IV Pavimentos e IV Telhados, e EG entre 60 a 73% nos restantes. Os classificadores com melhores resultados de EG obtidos foram o classificador Máxima Verosimilhança e Mahalanobis (como esperado, dadas as suas características probabilísticas intrínsecas), contrastando com os piores resultados globais obtidos pelos classificadores MAE e Codificação Binária.

Exactidão Global	Nível I	Nível II	Nível III		Nível IV		
			Não-Vegetação	Vegetação	Árvores	Pavimentos	Telhados
Paralelepípedo	76,4%	-- ³⁷	--	33,1%	66,4%	43,6%	--
Mínima Distância	40,9%	62,6%	51,8%	50,0%	66,4%	82,8%	68,5%
Mahalanobis	45,9%	81,3%	58,8%	54,6%	71,6%	83,0%	74,6%
Máxima Verosimilhança	81,1%	62,7%	69,8%	66,6%	72,9%	79,9%	89,5%
MAE	40,8%	65,1%	52,4%	51,6%	53,1%	73,4%	61,0%
Codificação Binária	--	--	--	--	49,7%	--	--

Tabela 16 - Exactidão global dos resultados dos vários classificadores no processo de classificação por níveis

No primeiro grupo, com valores de EG acima dos 80%, encontramos classes mais fáceis de classificar, i.e., cuja natureza espectral permite uma melhor discriminação. Destacamos o nível IV Telhados com um valor de EG de 89,5%. Este nível é constituído por quatro tipos de telhados: claros, médios, escuros e telhas laranja, para os quais, dada a sua natureza espectral, foi fácil seleccionar parcelas de treino capazes de providenciar aos classificadores informação com vista a um bom resultado. Dado este cenário era expectável que os melhores resultados fossem conseguidos pelos classificadores Máxima Verosimilhança (MV) e Distância de Mahalanobis (MAHA). por causa da sua natureza probabilística (classificadores paramétricos) em contraponto com os classificadores não-paramétricos³⁸.

Ao analisarmos os resultados de IK do processo de classificação por níveis (Tabela 17 e Tabela 18) verificamos que estes acompanham naturalmente o comportamento das EG, situando as melhores classificações num intervalo de concordância igual ou superior a Razoável, dando-nos assim uma maior confiança nos resultados obtidos.

No segundo grupo, com EG mais baixas, podemos verificar que inclui em geral classes mais difíceis de discriminar pela sua natureza espectral, e.g., no nível III Não-Vegetação as classes classificadas foram Telhados, Pavimentos, Solo Agrícola e Solo

³⁷ Existem classificadores que não conseguiram classificar todas as classes dos níveis em questão.

³⁸ Ver capítulo II.3 Classificadores supervisionados *pixel a pixel*

Nu. As classes Telhados e Pavimentos podem ter assinaturas espectrais semelhantes, o que dificulta a aquisição de parcelas de treino suficientemente puras para garantir uma boa separabilidade para a classificação. Assim, mais uma vez, verificámos que, como era previsível, os classificadores paramétricos têm melhor desempenho sobre os não-paramétricos, dada a riqueza espectral da imagem.

De facto, a génese probabilística deste tipo de algoritmos comporta-se bem em imagens de alta resolução espacial como é o caso da imagem utilizada.

Índice Kappa	Nível I	Nível II	Nível III		Nível IV		
			Não-Vegetação	Vegetação	Árvores	Pavimentos	Telhados
Paralelepípedo	0,393	--	--	0,033	0,090	0,040	--
Mínima Distância	0,076	0,324	0,297	0,228	0,372	0,640	0,345
Mahalanobis	0,096	0,584	0,396	0,335	0,451	0,645	0,493
Máxima Verosimilhança	0,462	0,204	0,550	0,435	0,459	0,604	0,719
MAE	0,018	0,394	0,355	0,206	0,109	0,511	0,319
Codificação Binária	--	--	--	--	0,033	--	--

Tabela 17 – Índice Kappa dos resultados dos vários classificadores no processo de classificação por níveis

Índice Kappa (qualitativo)	Nível I	Nível II	Nível III		Nível IV		
			Não-Vegetação	Vegetação	Árvores	Pavimentos	Telhados
Paralelepípedo	Razoável	--	--	Baixo	Baixo	Baixo	--
Mínima Distância	Baixo	Razoável	Razoável	Razoável	Razoável	Substancial	Razoável
Mahalanobis	Baixo	Moderado	Razoável	Razoável	Moderado	Substancial	Moderado
Máxima Verosimilhança	Moderado	Razoável	Moderado	Moderado	Moderado	Substancial	Substancial
MAE	Baixo	Razoável	Razoável	Razoável	Baixo	Moderado	Razoável
Codificação Binária	--	--	--	--	Baixo	--	--

Tabela 18 – Níveis de concordância do índice Kappa dos resultados dos vários classificadores no processo de classificação por níveis

IV.2 Processo de classificação por classes

A avaliação no processo de classificação por classes incidiu sobre as exactidões do utilizador (EU) de cada uma das classes e classificações dos vários níveis, com excepção da classe Sombra, que não foi objecto de processamento de classificação por não ser considerada alvo para o presente estudo. Para cada classe em cada nível seleccionámos a classificação com EU mais altas para serem utilizadas como máscaras para o cálculo do nível seguinte.

Considerámos para a nossa análise não apenas as EU mas também o IK igual ou superior a Razoável como forma de garantir uma melhor qualidade das classificações.

No primeiro nível, o classificador MV apresenta a melhor conjugação EU/IK para as classes em questão, com uma EU de 91,2% na classe Sombra e 79,5% na classe Não-Sombra e um IK Moderado para o nível classificado (Tabela 19). Estes resultados vêm ao encontro do expectável para um nível constituído por classes que permitem uma boa separabilidade, dada a sua natureza espectral. Apesar de os classificadores MD e MAHA apresentarem, para a classe Sombra um valor de EU de 98,9% e 97,2% respectivamente, estes não foram considerados por apresentarem um IK Baixo.

Nível I	Exactidão do Utilizador		Índice Kappa
	Sombra	Não-Sombra	
Paralelepípedo	90,5%	74,4%	0,393 / Razoável
Mínima Distância	98,9%	36,3%	0,076 / Baixo
Mahalanobis	97,2%	41,3%	0,096 / Baixo
Máxima Verosimilhança	91,2%	79,5%	0,462 / Moderado
MAE	44,2%	40,7%	0,018 / Baixo
Codificação Binária	--	--	-- / --

Tabela 19- Processo de classificação por classes
Nível I (Exactidão das classes e índice kappa do nível)

De referir ainda que, além do classificador Codificação Binária, que não conseguiu classificar correctamente as classes do nível, o classificador com piores resultados de EU foi o MAE, o que era igualmente expectável, dado tratar-se de um classificador que utiliza os ângulos espectrais para a classificação, o que se torna muito

difícil num nível em que as classes (Sombra e Não-Sombra) apresentam uma grande dispersão espacial na imagem.

O segundo nível apresenta uma divisão entre classificadores com as melhores EU (Tabela 20). O classificador MAHA obtém 77,8% de EU para a classe Vegetação, enquanto que a classe Não-Vegetação apresenta melhores resultados com o classificador Mínima Distância (MD) com uma EU de 96,0%.

Nível II – Não-Sombra	Exactidão do Utilizador		Índice Kappa
	Vegetação	Não-Vegetação	
Paralelepípedo	--	--	-- / --
Mínima Distância	51,3%	96,0%	0,324 / Razoável
Mahalanobis	77,8%	91,7%	0,584 / Moderado
Máxima Verosimilhança	29,0%	90,4%	0,204 / Razoável
MAE	57,5%	87,4%	0,394 / Razoável
Codificação Binária	--	--	-- / --

Tabela 20 - Processo de classificação por classes
Nível II Não-Sombra (Exactidão das classes e índice kappa do nível)

No nível III Não-Vegetação, podemos observar que as melhores EU estão divididas entre os classificadores MAHA e MV com valores entre os 64,8% e os 79,3% (Tabela 21).

Nível III – Não-Vegetação	Exactidão do Utilizador				Índice Kappa
	Telhados	Solo Nu	Pavimentos	Solo Agrícola	
Paralelepípedo	--	--	--	--	-- / --
Mínima Distância	41,4%	60,9%	64,1%	51,5%	0,297 / Razoável
Mahalanobis	46,3%	68,5%	79,1%	38,5%	0,396 / Razoável
Máxima Verosimilhança	64,8%	68,0%	79,3%	65,2%	0,550 / Moderado
MAE	35,5%	66,1%	73,6%	49,4%	0,355 / Razoável
Codificação Binária	--	--	--	--	-- / --

Tabela 21 - Processo de classificação por classes
Nível III Não-Vegetação (Exactidão das classes e índice kappa do nível)

São resultados que reflectem a dificuldade de classificar classes muito próximas espectralmente, sendo de esperar que nestes casos os melhores resultados surjam com classificadores paramétricos. Apesar destes resultados, existe a garantia de um razoável nível de concordância das classes classificadas com valores IK superiores a 0,396.

No nível III Vegetação verifica-se em primeiro lugar que existe um forte desequilíbrio nos resultados obtidos no classificador Paralelepípedo (PARA) nas três classes de Vegetação, sendo que a classe Árvores apresenta uma classificação muito alta em contraste com os resultados anormalmente baixos nas restantes (Vegetação Herbácea e Relva), o que é corroborado pela obtenção de um IK Baixo, indiciando uma classificação deficiente, e por essa razão foi desconsiderado.

Assim, nos restantes classificadores continuamos a assistir à supremacia do classificador MV na classificação das classes (Tabela 22).

Nível III – Vegetação	Exactidão do Utilizador			Índice Kappa
	Árvores	Vegetação Herbácea	Relva	
Paralelepípedo	99,5%	0,12%	3,4%	0,005 / Baixo
Mínima Distância	54,2%	47,2%	55,8%	0,217 / Razoável
Mahalanobis	61,6%	58,3%	50,7%	0,315 / Razoável
Máxima Verosimilhança	63,0%	70,7%	50,5%	0,417 / Moderado
MAE	44,4%	57,6%	32,6%	0,189 / Baixo
Codificação Binária	--	--	--	-- / --

**Tabela 22 - Processo de classificação por classes
Nível III Vegetação (Exactidão das classes e índice kappa do nível)**

De referir ainda a classe Relva com o resultado mais baixo entre as três classes (55,8%), classificada com o classificador MD. Este comportamento deve-se provavelmente à escassa presença da classe na área de estudo, facto que aumenta a dificuldade na classificação em alguns classificadores, nomeadamente os paramétricos.

O nível IV Árvores consegue um resultado de EU de 91,8% para as árvores escuras com o classificador MD, e de 66,2% para as árvores claras com o classificador MV (Tabela 23).

Nível IV – Árvores	Exactidão do Utilizador		Índice Kappa
	Claras	Escuras	
Paralelepípedo	98,5%	9,9%	0,102 / Baixo
Mínima Distância	51,0%	91,8%	0,390 / Razoável
Mahalanobis	60,2%	90,1%	0,468 / Moderado
Máxima Verosimilhança	66,2%	84,5%	0,482 / Moderado
MAE	52,9%	53,0%	0,140 / Baixo
Codificação Binária	43,4%	65,9%	0,086 / Baixo

Tabela 23- Processo de classificação por classes
Nível IV Árvores (Exactidão das classes e índice Kappa do nível)

Também nesta classe se verifica no classificador PARA um forte desequilíbrio entre as duas classes do nível (Árvores Claras e Árvores Escuras), apresentando a classe Árvores Claras uma classificação muito alta em contraste com os resultados anormalmente baixos na classe Árvores Escuras, o que é corroborado pela obtenção de um IK Baixo, indiciando uma classificação deficiente, tendo por essa razão sido desconsiderado.

Considerámos que, mais uma vez, apesar de o classificador PARA mostrar um resultado melhor para as árvores claras, não indicia uma boa concordância de valores com um IK muito baixo.

Nos níveis IV, Pavimentos e Telhados, continuamos a verificar a homogeneidade dos classificadores paramétricos com os classificadores MV e MAHA a dividirem as melhores EU para as classes em questão (Tabela 24 e Tabela 25).

Nível IV – Pavimentos	Exactidão do Utilizador		Índice Kappa
	Claros	Escuros	
Paralelepípedo	99,7%	5,1%	0,040 / Baixo
Mínima Distância	76,4%	87,1%	0,640 / Substancial
Mahalanobis	76,7%	87,4%	0,645 / Substancial
Máxima Verosimilhança	91,0%	72,4%	0,604 / Substancial
MAE	83,1%	66,8%	0,511 / Moderado
Codificação Binária	--	--	-- / --

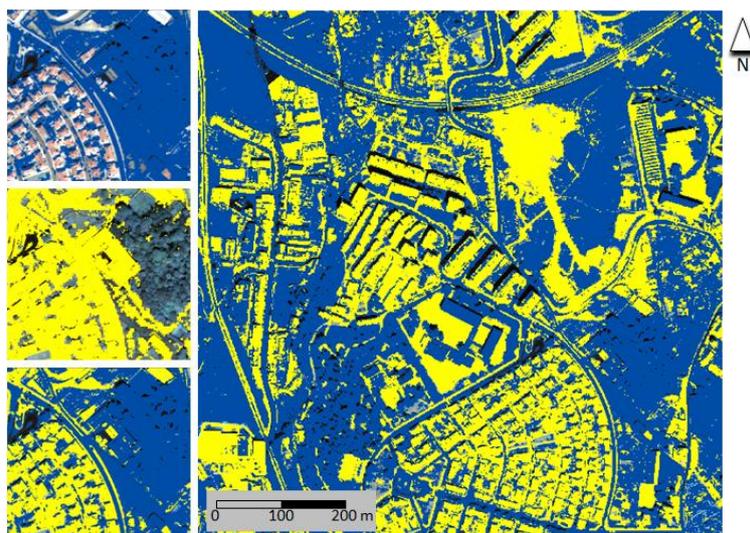
Tabela 24 - Processo de classificação por classes
Nível IV Pavimentos (Exactidão das classes e índice kappa do nível)

Nível IV – Telhados	Exactidão do Utilizador				Índice Kappa
	Telha Laranja	Claros	Médios	Escuros	
Paralelepípedo	--	--	--	--	-- / --
Mínima Distância	69,2%	84,1%	48,1%	89,1%	0,345 / Razoável
Mahalanobis	72,6%	87,4%	77,3%	90,5%	0,493 / Moderado
Máxima Verosimilhança	91,9%	93,4%	71,5%	81,6%	0,719 / Substancial
MAE	62,6%	80,5%	44,2%	45,6%	0,319 / Razoável
Codificação Binária	---	--	--	--	-- / --

Tabela 25 - Processo de classificação por classes
Nível IV Telhados (Exactidão das classes e índice kappa do nível)

IV.3 Processo de classificação por níveis vs Processo de classificação por classes

Para cada um dos processos elaborámos um mapa com os melhores resultados obtidos para a nomenclatura de classes final apresentada na Tabela 14, para assim conseguirmos comparar os resultados das duas abordagens. Contudo, é preciso salientar que este agrupamento de classes é um processo bastante sensível. Trata-se de uma junção de classificações de classes provenientes de diferentes classificadores, o que poderá resultar na sobreposição de algumas classes (Figura 20). Para minimizar o efeito da sobreposição de classes elaborámos um esquema de pesos para cada um dos resultados dos processos de classificação, atribuindo a cada classe a sua EU como peso (Tabela 26 e Tabela 27).



Não-Vegetação (Classificador MAHA)
 Vegetação (Classificador MD)

Figura 20 - Nível II Não-Sombra do PCC - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Não-Vegetação; classe Vegetação; resolução da sobreposição). À direita mapa final

Nível	Classes	Peso· (exactidão do utilizador)	Classificador
Nível III – Vegetação	Relva	57,4%	Máxima Verossimilhança
	Vegetação Herbácea	70,1%	
Nível III Não Vegetação	Solo Nu	68,0%	Máxima Verossimilhança
	Solo Agrícola	65,2%	
Nível IV Árvores	Árvores Claras	67,7%	Máxima Verossimilhança
	Árvores Escuras	81,8%	
Nível IV Telhados	Telhados Claros	93,4%	Máxima Verossimilhança
	Telhados Médios	71,5%	
	Telhados Telha Laranja	91,9%	
	Telhados Escuros	81,6%	
Nível IV Pavimentos	Pavimentos Claros	76,7%	Mahalanobis
	Pavimentos Escuros	87,4%	

**Tabela 26 - Pesos atribuídos às classes da nomenclatura final.
Processo de classificação por níveis**

Nível	Classes	Peso (exactidão do utilizador)	Classificador
Nível III – Vegetação	Relva	55,8%	Mínima Distância
	Vegetação Herbácea	70,7%	Máxima Verosimilhança
Nível III Não Vegetação	Solo Nu	68,5%	Mahalanobis
	Solo Agrícola	65,2%	Máxima Verosimilhança
Nível IV Árvores	Árvores Claras	66,2%	Máxima Verosimilhança
	Árvores Escuras	91,8%	Mínima Distância
Nível IV Telhados	Telhados Claros	93,4%	Máxima Verosimilhança
	Telhados Médios	77,3%	Mahalanobis
	Telhados Telha Laranja	91,9%	Máxima Verosimilhança
	Telhados Escuros	90,5%	Mahalanobis
Nível IV Pavimentos	Pavimentos Claros	91,0%	Máxima Verosimilhança
	Pavimentos Escuros	87,4%	Mahalanobis

**Tabela 27 - Pesos atribuídos às classes da nomenclatura final.
Processo de classificação por classes**

Feita esta atribuição de pesos a todas as classes da nomenclatura final, seguimos um fluxograma de decisão para resolver todas as sobreposições de classes (Figura 21). Considerámos assim, em cada caso de sobreposição, que a classe com maior EU se reporta à classificação que estará mais próxima da realidade, sendo por isso considerada na realização do mapa final.

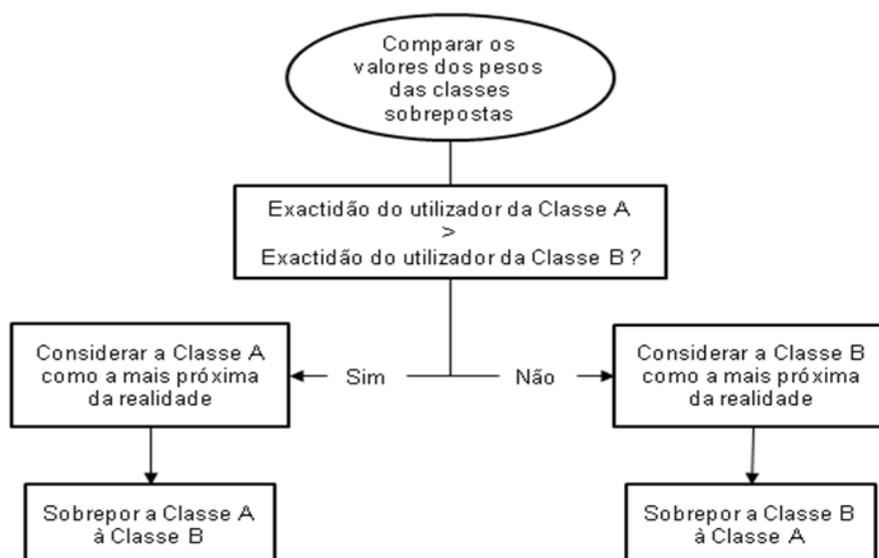


Figura 21 - Fluxograma de decisão sobre a sobreposição das classes

As Tabela 28 e Tabela 29 apresentam as classes da nomenclatura de classes final antes e depois da resolução das sobreposições das classes.

Podemos verificar nas duas tabelas que houve um sério decréscimo de EU em relação às EU originais (antes da aplicação dos pesos nos casos de sobreposição). As classes que foram mais prejudicadas no caso do processo de classificação por níveis (PCN), com uma diferença entre exactidões de cerca de 74.0% foram, no nível IV Telhados, os Telhados Claros e os Telhados de Telha Laranja (Tabela 28). O mesmo não se verificou no entanto nas classes Solo Agrícola (nível III Não-Vegetação), e Árvores Escuras (nível III Vegetação), que registaram uma diferença muito baixa de EUs entre a EU verificada antes e a EU verificada depois da resolução da sobreposição (menos de 0,9%).

Nível	Classes	Exactidão do utilizador	
		Extraída dos níveis	Mapa final (depois da aplicação dos pesos)
Nível III – Vegetação	Relva	57,4%	52,1%
	Vegetação Herbácea	70,1%	23,1%
Nível III Não Vegetação	Solo Nu	68,0%	43,8%
	Solo Agrícola	65,2%	64,8%
Nível IV Árvores	Árvores Claras	67,7%	41,1%
	Árvores Escuras	81,8%	80,9%
Nível IV Telhados	Telhados Claros	93,4%	19,2%
	Telhados Médios	71,5%	63,4%
	Telhados Telha Laranja	91,9%	17,8%
	Telhados Escuros	81,6%	72,9%
Nível IV Pavimentos	Pavimentos Claros	76,7%	53,3%
	Pavimentos Escuros	87,4%	69,9%

**Tabela 28- Comparação entre as EU dos níveis e as EU do mapa final.
Processo de classificação por níveis**

Nos resultados provenientes do processo de classificação por classes (PCC) as maiores diferenças dão-se no nível IV Telhados, sendo as classes Vegetação Herbácea e Solo Agrícola as classes com menores diferenças entre EU (Tabela 29).

Nível	Classes	Exactidão do utilizador	
		Extraída das classes	Mapa final (depois da aplicação dos pesos)
Nível III – Vegetação	Relva	55,8%	43,3%
	Vegetação Herbácea	70,7%	68,6%
Nível III Não Vegetação	Solo Nu	68,5%	58,9%
	Solo Agrícola	65,2%	68,1%
Nível IV Árvores	Árvores Claras	66,2%	31,2%
	Árvores Escuras	91,8%	82,0%
Nível IV Telhados	Telhados Claros	93,4%	19,7%
	Telhados Médios	77,3%	13,6%
	Telhados Telha Laranja	91,9%	3,1%
	Telhados Escuros	90,5%	45,0%
Nível IV Pavimentos	Pavimentos Claros	91,0%	69,5%
	Pavimentos Escuros	87,4%	73,6%

Tabela 29 - Comparação entre as EU dos níveis e as EU do mapa final
Processo de classificação por classes

Comparando os resultados dos dois processos, antes da aplicação dos pesos às classes, verificamos que são bastante semelhantes (Tabela 30). No entanto, em quatro classes – Árvores Escuras, Telhados Médios, Telhados Escuros, e Pavimentos Claros – podemos verificar melhores resultados no PCC.

Nível	Classes	Exactidão do Utilizador	
		PCN	PCC
Nível III – Vegetação	Relva	57,4%	55,8%
	Vegetação Herbácea	70,1%	70,7%
Nível III Não Vegetação	Solo Nu	68,0%	68,5%
	Solo Agrícola	65,2%	65,2%
Nível IV Árvores	Árvores Claras	67,7%	66,2%
	Árvores Escuras	81,8%	91,8%
Nível IV Telhados	Telhados Claros	93,4%	93,4%
	Telhados Médios	71,5%	77,3%
	Telhados Telha Laranja	91,9%	91,9%
	Telhados Escuros	81,6%	90,5%
Nível IV Pavimentos	Pavimentos Claros	76,7%	91,0%
	Pavimentos Escuros	87,4%	87,4%

Tabela 30 - Quadro comparativo dos resultados das classes dos processos de classificação antes de aplicados os pesos às classes

Já quando comparamos os resultados depois de aplicados os pesos às classes (Tabela 31), assistimos a um decréscimo de EU bastante acentuado. Existem diferenças consideráveis entre os resultados dos dois processos de classificação na maioria das classes. Com efeito apenas as classes Solo Agrícola, Árvores Escuras, Telhados Claros e Pavimentos Escuros apresentam diferenças baixas. Contudo, podemos verificar que as EG de ambos os processos são próximas, tendo um índice de concordância (IK) classificado como Moderado.

Nível	Classes	Exactidão do Utilizador	
		PCN	PCC
Nível III – Vegetação	Relva	52,1%	43,3%
	Vegetação Herbácea	23,1%	68,6%
Nível III Não Vegetação	Solo Nu	43,8%	58,9%
	Solo Agrícola	64,8%	68,1%
Nível IV Árvores	Árvores Claras	41,1%	31,2%
	Árvores Escuras	80,9%	82,0%
Nível IV Telhados	Telhados Claros	19,2%	19,7%
	Telhados Médios	63,4%	13,6%
	Telhados Telha Laranja	17,8%	3,1%
	Telhados Escuros	72,9%	45,0%
Nível IV Pavimentos	Pavimentos Claros	53,3%	69,5%
	Pavimentos Escuros	69,9%	73,6%
Exactidão Global		54,1	51,6%
Índice Kappa		0,483 / Moderado	0,455 / Moderado

**Tabela 31 - Quadro comparativo do mapa final dos dois processos
depois de aplicados os pesos às classes**

Como referido anteriormente a construção de um mapa final das nomenclaturas pressupõe um processo de decisão delicado. Será sempre um compromisso assumir que as classes com uma EU mais elevada serão as que melhor reflectem a realidade.

IV.4 Processos de classificação propostos vs Classificação directa das classes mais discriminantes

Para podermos inferir sobre qualidade das abordagens propostas face à classificação feita aplicando directamente as parcelas de treino da nomenclatura proposta (Tabela 14), apresentamos de seguida um quadro comparativo das três classificações.

A classificação directa das classes mais discriminantes com todos os seis classificadores revelou que o classificador com o qual se obtêm os melhores resultados é o classificador Máxima Verosimilhança (Tabela 32).

Mapa Final	Exactidão Global	Índice Kappa
Paralelepípedo	--	--
Mínima Distância	38,6%	0,321 / Razoável
Mahalanobis	43,1%	0,370 / Razoável
Máxima Verosimilhança	55,4%	0,501 / Moderado
MAE	37,9%	0,322 / Razoável
Codificação Binária	--	--

Tabela 32 - Exactidões dos resultados dos seis classificadores para o Mapa Final³⁹

³⁹ Os classificadores Paralelepípedo e Codificação Binária não conseguiram classificar todas as classes da nomenclatura final.

Na Tabela 33 comparámos as EUs das classes obtidas ao longo dos processos de classificação propostos com a EU das classes obtidas pela classificação directa das classes mais discriminantes (Tabela 14).

Nível	Classes	Exactidão do Utilizador		
		PCN	PCC	Classificação directa
Nível III – Vegetação	Relva	57,4%	55,8%	32,2%
	Vegetação Herbácea	70,1%	70,7%	60,3%
Nível III Não Vegetação	Solo Nu	68,0%	68,5%	65,2%
	Solo Agrícola	65,2%	65,2%	59,2%
Nível IV Árvores	Árvores Claras	67,7%	66,2%	44,2%
	Árvores Escuras	81,8%	91,8%	78,6%
Nível IV Telhados	Telhados Claros	93,4%	93,4%	58,0%
	Telhados Médios	71,5%	77,3%	37,6%
	Telhados Telha Laranja	91,9%	91,9%	53,3%
	Telhados Escuros	81,6%	90,5%	50,7%
Nível IV Pavimentos	Pavimentos Claros	76,7%	91,0%	46,5%
	Pavimentos Escuros	87,4%	87,4%	78,9%
Exactidão Global		N/A	N/A	55,4%
Índice Kappa		N/A	N/A	0,501 / Moderado

Tabela 33 – Comparação de exactidões do utilizador dos processos de classificação (antes da aplicação dos pesos às classes) com a classificação directa das classes mais discriminantes

Podemos verificar uma clara superioridade na exactidão alcançada por qualquer um dos processos em estudo quando comparadas com a classificação directa das classes mais discriminantes (CDCD), existindo somente um caso onde os valores se aproximam (Solo Nu).

Contudo, uma questão pertinente se levanta na análise deste primeiro quadro – é legítimo comparar resultados dos processos de classificação propostos, resultantes de diferentes classificadores? A resposta, em nosso entender, deverá ser negativa. De facto, existem sobreposições de classes provenientes de diferentes classificadores, e naturalmente a decisão será sobre qual das classes terá maior peso sobre a outra.

O método de decisão proposto (Figura 21) teve como factor de decisão a EU das classes, optando pela classe com maior EU em caso de sobreposição. Podemos verificar à partida que os valores de EU resultantes da junção das classes provenientes num só mapa (Tabela 34) em ambos os processos de classificação decresceu significativamente, passando por exemplo, no caso da classe Telhados Claros e em ambos os processos (PCN e PCC), de 93,4% antes da aplicação dos pesos às classes, para cerca de 19,2% depois dessa aplicação, valor que fica nos 58,0% no caso da CDCD.

Nível	Classes	Exactidão do Utilizador		
		PCN	PCC	Classificação directa
Nível III – Vegetação	Relva	52,1%	43,3%	32,2%
	Vegetação Herbácea	23,1%	68,6%	60,3%
Nível III Não Vegetação	Solo Nu	43,8%	58,9%	65,2%
	Solo Agrícola	64,8%	68,1%	59,2%
Nível IV Árvores	Árvores Claras	41,1%	31,2%	44,2%
	Árvores Escuras	80,9%	82,0%	78,6%
Nível IV Telhados	Telhados Claros	19,2%	19,7%	58,0%
	Telhados Médios	63,4%	13,6%	37,6%
	Telhados Telha Laranja	17,8%	3,1%	53,3%
	Telhados Escuros	72,9%	45,0%	50,7%
Nível IV Pavimentos	Pavimentos Claros	53,3%	69,5%	46,5%
	Pavimentos Escuros	69,9%	73,6%	78,9%
Exactidão Global		54,1%	51,6%	55,4%
Índice Kappa		0,483 / Moderado	0,455 / Moderado	0,501 / Moderado

Tabela 34 - Comparação de exactidões do utilizador obtidas convergindo as classes dos processos de classificação propostos (depois da aplicação dos pesos às classes) num mapa final com a classificação das classes mais discriminantes

Se compararmos as EG dos diferentes processos verificamos o que anteriormente afirmámos. O PCN com 54,1% e o PCC com 51,6% de EG não ultrapassam os 55,4% conseguidos pela CDCD. Verificamos também uma concordância Moderada de IK em todas as classificações.

Verificamos assim que enquanto os 2 processos testados permitem obter classes melhor classificadas isoladamente, os mapas finais de ambos os processos não ganham em EG quando comparados com uma classificação directa, o que se deve ao facto de a aplicação dos pesos, tendo como base as EUs das classes, não garantir que se opte pela classe mais próxima da realidade. Portanto, existem classes que, por terem uma EU maior, se sobrepuseram a outras que seriam, essas sim, as mais próximas da realidade, levando a que o mapa final com essas classes apresentasse uma EG mais baixa quando comparado com a CDCD.

Capítulo V: Conclusões

A investigação efectuada permitiu comprovar que, sendo incontestável a clara vantagem na utilização de imagens provenientes de sensores de alta resolução espacial para o estudo do meio urbano, a riqueza espacial que este tipo de imagens possui, a que se juntam outros factores como as limitações espectrais, a complexidade do meio, e as limitações dos classificadores e do nosso próprio conhecimento do meio, são factores que nos levam a enfrentar problemas na correcta classificação do uso do solo em meio urbano.

Estas contrariedades radicam desde logo na dificuldade de escolher parcelas de treino suficientemente caracterizadoras de uma determinada classe temática, devido à variância espectral dentro de um mesmo tema e à existência de semelhanças espectrais em classes diferentes (por exemplo, entre Telhados Escuros e Pavimentos Escuros).

Com os dois processos de classificação utilizados – Processo de Classificação por Níveis (PCN) e Processo de Classificação por Classes (PCC) – procurámos explorar os classificadores em estudo e minimizar os possíveis erros nas classificações por meio de segmentações, utilizando como máscaras de classificação as classes dos níveis melhor classificados no caso do PCN ou as melhores classes em cada nível no caso do PCC.

Os resultados demonstraram que existe um aumento considerável de exactidão das classes quando sujeitas aos processos de classificação propostos, com especial relevo para a hegemonia dos classificadores paramétricos dada a sua natureza probabilística, factor que adquire especial relevância em imagens de alta resolução espacial e com uma temática de meio urbano que torna a caracterização de classes por meio de parcelas de treino uma tarefa delicada.

Comparando os processos de classificação usados podemos concluir que nenhum dos dois se destacou, pois ambos conseguem exactidões semelhantes. No entanto, é de referir que, não se destacando nenhum processo de classificação no que diz respeito às exactidões resultantes da classificação hierárquica, poder-se-á optar pelo PCN, pois mostra-se o mais expedito no que diz respeito à rapidez de aplicação e obtenção de resultados.

A comparação dos resultados obtidos nos dois processos com um mapa resultante da classificação directa das doze classes mais discriminantes da hierarquia de classes proposta (CDCD) revelou que não existe uma clara vantagem na aplicação dos processos em estudo, uma vez que os resultados em termos de Exactidão Global foram muito semelhantes. No entanto, tal conclusão poderá estar enviesada por ter sido necessário resolver problemas de sobreposição de classes quando, em qualquer um dos processos de classificação, essas classes são provenientes de classificadores diferentes. Esta necessidade levou à opção por uma metodologia de resolução das sobreposições que implicou o decréscimo verificado na EG nas classes submetidas a este processo.

Com efeito, a comparação directa das exactidões das classes obtidas no decorrer dos dois processos de classificação (PCN e PCC) com o resultado da CDCD revela que qualquer um daqueles processos de classificação obtém melhores resultados do que a metodologia clássica de classificação de classes (CDCD). No entanto, esta comparação levanta dúvidas metodológicas, uma vez que as classes obtidas são provenientes de classificadores diferentes, o que se pode traduzir numa sobreposição de classes aquando da tentativa de junção das várias classes de um processo num só mapa. A aplicação de um processo de decisão ponderado pela EU como metodologia de resolução das sobreposições verificadas, mostrou-se uma estratégia pouco eficaz, ao obter resultados de EU para as classes dos processos de classificação globalmente bastante mais baixos do que as classes do mapa da CDCD. Da mesma forma, a EG revelou-se igualmente mais baixa, não ultrapassando os 51,6% nos processos de classificação, enquanto na CDCD se obteve uma EG de 55,4%. Desta forma, não se verificam vantagens comparativas relevantes na junção de classes provenientes de diferentes classificadores num só mapa.

Levantam-se assim algumas questões que deverão merecer um estudo mais aprofundado em trabalhos futuros. Em primeiro lugar, parece-nos interessante explorar a problemática da sobreposição de classes provenientes de diferentes classificadores, estudando outro tipo de parâmetros que auxiliem o refinamento do resultado final do mapa resultante da junção das várias classes, como por exemplo decisores estatísticos, que poderão levar a resultados mais interessantes no que diz respeito à exactidão das classificações. Em segundo lugar, a substituição dos classificadores supervisionados por classificadores orientados por objectos nos processos de classificação propostos. Por

último, aplicar os processos de classificação noutro tipo de malha urbana para avaliar o seu comportamento noutro tipo de classes temáticas.

Bibliografia de referência

Cohen, J. A., 1960. Coefficient of Agreement for Nominal Scales, *Educational and Psychological Measurement* - v.20, n.1, p. 37-46.

• Freire S., Santos T., Navarro, A., Soares F., Dinis J., Afonso N., Fonseca A., Tenedório J. A., (2010). Extraction of buildings from QuickBird imagery for municipal planning purposes: quality assessment considering existing mapping standards. *Proceedings of GEOBIA2010*. Ghent, 29 June – July 2, 2010

• Freire S., Santos T., Gomes N., Fonseca A., Tenedório J. A. (2010). Extraction of buildings from QuickBird imagery – what is the relevance of urban context and heterogeneity? *Proceedings of ASPRS/CaGIS/ISPRS Fall Conference*. Orlando, November 15 – 18, 2010.

Lillesand, T.M. e Kiefer, R.W., 1994. *Remote Sensing and Image Interpretation*. *New York: John Wiley & Sons*.

Santos T., Freire S., Navarro, A., Silva J., Soares F., Fonseca A., Tenedório J. A. (2010). Extracting buildings in the city of Lisbon using QuickBird images and LiDAR data. *Proceedings of GEOBIA2010*. Ghent, 29 June – July 2, 2010.

Bibliografia geral e Fontes

Blumberg, D. G. e Zhu, G., 2007. Using a hierarchical multi-resolution mechanism for the classification and semantic extraction of landuse maps for Beer-Sheva, Israel. *International Journal of Remote Sensing* - 28:15,3273 - 3289.

Carleer, A. P. e Wolff, E., 2006. Urban land cover multi-level region-based classification of VHR data by selecting relevant features. *International Journal of Remote Sensing* - 27:6,1035 – 1051.

Chen, Y., Shi, P., Fung, T., Wang, J. e Li, X., 2007. Object-oriented classification for urban land cover mapping with ASTER imagery. *International Journal of Remote Sensing* - 28:20,4645 - 4651.

Dell'Acqua, F. D., Gamba, P., Ferrari, A., Palmason, J.A., Benediktsson, J. A., Arnason, K., 2004. Exploiting Spectral and Spatial Information in Hyperspectral Urban Data With High Resolution. *IEEE Geoscience ad remote sensing letters*, vol. 1, no. 4.

• Freire S., Santos T., Tenedório J., and Fonseca A., 2008. Extracção de objectos geográficos em áreas urbanas densas a partir de imagens de satélite com alta resolução espacial. Actas do ESIG'2008 - X Encontro de Utilizadores de Informação Geográfica. Oeiras, Portugal, 14-16 de Maio, 2008, pp. 279-293

Herold, M., Liu, X. e Clarke, K.C., 2003. Spatial metrics and image texture for mapping urban land use. *Photogrammetric Engineering and Remote Sensing* - 69, pp. 991–1001.

Herold, M., Gardner, M. E., e Roberts, D. A., 2003. Spectral resolution requirements for mapping urban areas. *IEEE Transactions on geoscience and remote sensing* - vol.41, no.9.

Jat, M. K., Garg, P. K. e Khare, D.. 2007. Modelling of urban growth using spatial analysis techniques: a case study of Ajmer city (India). *International Journal of Remote Sensing* - 29:2,543 – 567.

Lavigne, D., Hong, G, e Zhang, Y., 2006. Performance assessment of automated feature extraction tools on high resolution imagery. *Proceedings of the ASPRS Annual Conference*, 6-10 November, San Antonio, TX.

Lu, D. and Weng, Q., 2007. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing* - 28:5, 823 – 870.

M. K. Jat; P. K. Garg; D. Khare, 2007. Modelling of urban growth using spatial analysis techniques: a case study of Ajmer city (India). Indian Institute of Technology Roorkee, Roorkee, India.

Maktav, D., Erbek, F. S. e Jürgens, C., 2005. Remote sensing of urban areas. *International Journal of Remote Sensing* - 26:4,655 – 659.

Su, W., Li, J., Chen, Y., Liu, Z., Zhang, J., Low, T. M., Suppiah, I. e Hashim, S. A. M., 2008. Textural and local spatial statistics for the object-oriented classification of urban areas using high resolution imagery. *International Journal of Remote Sensing* - 29:11,3105 – 3117.

Shackelford, A. K. and Davis, C. H., 2003. A Hierarchical Fuzzy Classification Approach for High-Resolution Multispectral Data Over Urban Areas. *IEEE Transactions on Geoscience and Remote Sensing* - vol. 41, no. 9.

O'Brien, M., 2003. Feature Extraction with the VLS Feature Analyst System. *Proceedings of the ASPRS Annual Conference* - 3-9 May, Anchorage, AK.

Thomas, N., Hendrix, C. E Congalton, R.G., 2003. A comparison of urban mapping methods using high-resolution digital imagery. *Photogrammetric Engineering and Remote Sensing* - 69, pp. 963 – 972.

Heiden, U., Segl, K., Roessner, S. e Kaufmann, H., 2007. Determination of robust spectral features for identification of urban surface materials in hyperspectral remote sensing data. *Remote Sensing of Environment* - 537-552.

Zhou, W. e Troy, A., 2008. An object-oriented approach for analysing and characterizing urban landscape at the parcel level. *International Journal of Remote Sensing* - 29:11,3119 – 3135.

Tenedório, José A., 2007. GeoSat – Metodologias para extracção de informação GEOgráfica a grande escala a partir de imagens de SATélite de alta resolução. Projecto da FCSH em curso, financiado pela FCT, in <http://www.fct.mctes.pt/projectos/concursos/index.asp?area=9&pid=64826>.

Welch, R., 1982. Spatial resolution requirements for urban studies. *International Journal of Remote Sensing* - 3(2), 138–146.

Kux, H. J. H. e Araújo, E. H. G., 2006. Multi-temporal object-oriented classification and analysis of QuickBird scenes at a metropolitan area in Brazil (Belo Horizonte, Minas Gerais State. INPE - SP Brazil.

Lillesand, T. M. e Kiefer, R. W., 1999. Remote sensing and image interpretation. Fourth edition, Wiley.

Richards, John A. e Jia, Xiuping, 2006. Remote Sensing Digital Image Analysis. Fourth edition, Springer-Verlag Berlin Heidelberg.

Lista de Figuras

Figura 1 - Imagem QuickBird utilizada	10
Figura 2 - Rede hierárquica.....	15
Figura 3 - Hierarquia de classes e respectivas características e regras de separação	17
Figura 4 – Espectro electromagnético.....	21
Figura 5- Caracterização hierárquica de materiais urbanos de superfície.....	23
Figura 6 - Árvore de decisão usada no processo de classificação hierárquica.....	25
Figura 7- Diagrama de árvore de decisão para classificação	26
Figura 8 - Histograma para os componentes bi-dimensionais da informação espectral de uma parcela de treino.....	34
Figura 9 - Exemplo de rectângulos representativos de classes num gráfico bi- dimensional de duas bandas.	34
Figura 10 - Exemplo de inseparabilidade resultante do classificador paralelepípedo.....	35
Figura 11 - Princípio do classificador de máxima verosimilhança.	36
Figura 12 – Exemplo das distâncias de um pixel aos centróides de várias parcelas de treino.	38
Figura 13 – Exemplo de duas amostras espectrais com o mesmo centróide mas com diferentes dispersões.....	38
Figura 14 – Princípio do classificador distância de Mahalanobis.....	39
Figura 15 - À esquerda dois elementos com o mesmo ângulo e magnitudes diferentes. À direita elementos com ângulos diferentes e magnitudes diferentes.....	40
Figura 16 - Hierarquia de classes (nomenclatura proposta para a zona abrangida pela imagem <i>QuickBird</i>).....	46
Figura 17 - Mapa de referência para as classes mais discriminantes.....	50
Figura 18- Fluxograma do processo de classificação por níveis	52
Figura 19 - Fluxograma do processo de classificação por classes.....	54

Figura 20 - Nível II Não-Sombra do PCC - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Não-Vegetação; classe Vegetação; resolução da sobreposição). À direita mapa final.....	64
Figura 21 - Fluxograma de decisão sobre a sobreposição das classes	66
Figura 22 – Mapa de referência para o Nível I	94
Figura 23 - Mapa de referência para o Nível II Não-Sombra	94
Figura 24 - Mapa de referência para o Nível III Não-Vegetação	95
Figura 25 - Mapa de referência para o Nível III Vegetação	95
Figura 26 - Mapa de referência para o Nível IV Árvores	96
Figura 27 - Mapa de referência para o Nível IV Pavimentos	96
Figura 28 - Mapa de referência para o Nível IV Telhados	97
Figura 29 - Nível I - Classificador de Máxima Verosimilhança.....	98
Figura 30 - Nível II - Classificador Distância de Mahalanobis	98
Figura 31 - Nível III Não-Vegetação - Classificador de Máxima Verosimilhança	99
Figura 32 - - Nível III Vegetação - Classificador de Máxima Verosimilhança....	99
Figura 33 - Nível IV Árvores - Classificador de Máxima Verosimilhança.....	100
Figura 34 - Nível IV Árvores - Classificador de Distância Mahalanobis.....	100
Figura 35 - Nível IV Telhados - Classificador de Máxima Verosimilhança	101
Figura 36 - Nível I - Classificador de Máxima Verosimilhança.....	102
Figura 37 - Nível II Não-Sombra - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Não-Vegetação; classe Vegetação; resolução da sobreposição). À direita mapa final.....	103
Figura 38 - Nível III Não-Vegetação - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Solo Nu; classe Telhados; resolução da sobreposição). À direita mapa final.....	103

Figura 39 - Nível III Não-Vegetação - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Árvores; classe Relva; resolução da sobreposição). À direita mapa final	104
Figura 40 - Nível IV Árvores - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Árvores Claras; classe Árvores Escuros; resolução da sobreposição). À direita mapa final	104
Figura 41- Nível IV Pavimentos - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Pavimentos Claros; classe Pavimentos Escuros; resolução da sobreposição). À direita mapa final	105
Figura 42 - Nível IV Telhados - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Telha Laranja; classe Telhados Escuros; resolução da sobreposição). À direita mapa final	105
Figura 43 - Mapa final do processo PCN.....	106
Figura 44 - Mapa final do processo PCC	107

Lista de tabelas

Tabela 1- Especificações do sensor Thematic Mapper dos satélites Landsat 4-5...	2
Tabela 2 - Especificações do satélite IKONOS	3
Tabela 3 - Especificações do satélite <i>QuickBird</i>	3
Tabela 4 - Classificadores supervisionados disponíveis no software ENVI.....	5
Tabela 5 - Chaves de pesquisa	8
Tabela 6 – Hierarquia de classes adoptada no estudo	12
Tabela 7 - Definição de classes	14
Tabela 8 – Legenda de classes	16
Tabela 9 - Esquema da classificação da imagem para a área em estudo	20
Tabela 10 - Sistema hierárquico de classificação	26
Tabela 11 - Classes para a zona de teste	28
Tabela 12- Exemplo de uma matriz de confusão. Fonte: do autor.....	41
Tabela 13 - Medidas de concordância do índice Kappa.	43
Tabela 14 – Nomenclatura final com as classes mais discriminantes da zona de estudo.....	47
Tabela 15 – Ordem do processo de classificação.....	48
Tabela 16 - Exactidão global dos resultados dos vários classificadores no processo de classificação por níveis	57
Tabela 17 – Índice Kappa dos resultados dos vários classificadores no processo de classificação por níveis	58
Tabela 18 – Níveis de concordância do índice Kappa dos resultados dos vários classificadores no processo de classificação por níveis.....	58
Tabela 19- Processo de classificação por classes Nível I (Exactidão das classes e índice kappa do nível).....	59

Tabela 20 - Processo de classificação por classes Nível II Não-Sombra (Exactidão das classes e índice kappa do nível)	60
Tabela 21 - Processo de classificação por classes Nível III Não-Vegetação (Exactidão das classes e índice kappa do nível)	60
Tabela 22 - Processo de classificação por classes Nível III Vegetação (Exactidão das classes e índice kappa do nível)	61
Tabela 23- Processo de classificação por classes Nível IV Árvores (Exactidão das classes e índice Kappa do nível).....	62
Tabela 24 - Processo de classificação por classes Nível IV Pavimentos (Exactidão das classes e índice kappa do nível)	62
Tabela 25 - Processo de classificação por classes Nível IV Telhados (Exactidão das classes e índice kappa do nível)	63
Tabela 26 - Pesos atribuídos às classes da nomenclatura final. Processo de classificação por níveis	64
Tabela 27 - Pesos atribuídos às classes da nomenclatura final. Processo de classificação por classes	65
Tabela 28- Comparação entre as EU dos níveis e as EU do mapa final. Processo de classificação por níveis	67
Tabela 29 - Comparação entre as EU dos níveis e as EU do mapa final Processo de classificação por classes.....	68
Tabela 30 - Quadro comparativo dos resultados das classes dos processos de classificação antes de aplicados os pesos às classes.....	69
Tabela 31 - Quadro comparativo do mapa final dos dois processos depois de aplicados os pesos às classes	70
Tabela 32 - Exactidões dos resultados dos seis classificadores para o Mapa Final	71
Tabela 33 – Comparação de exactidões do utilizador dos processos de classificação (antes da aplicação dos pesos às classes) com a classificação directa das classes mais discriminantes	72

Tabela 34 - Comparação de exactidões do utilizador obtidas convergindo as classes dos processos de classificação propostos (depois da aplicação dos pesos às classes) num mapa final com a classificação das classes mais discriminantes	73
Tabela 35 - Exemplo do resultado do operador "OU exclusivo"	90
Tabela 36 - Nível I - Exactidões do PCN - Classificador MV	91
Tabela 37 - Nível II Não-Sombra - Exactidões do PCN - Classificador MAHA .	91
Tabela 38 - Nível II Não-Sombra - Exactidões do PCN – Classificador MV	91
Tabela 39 - Nível II Vegetação - Exactidões do PCN – Classificador MV	92
Tabela 40 - Nível II Árvores - Exactidões do PCN – Classificador MV	92
Tabela 41 - Nível II Pavimentos - Exactidões do PCN – Classificador MAHA ..	92
Tabela 42 - Nível II Telhados - Exactidões do PCN – Classificador MV	93

Glossário

ArcGIS	Software de processamento de sistemas de informação geográfica
AVIRIS	Airborne Visible/InfraRed Imaging Spectrometer
B-On	Biblioteca do Conhecimento On-line
ENVI	Software para processamento e análise de imagens de satélite
IKONOS 2	Satélite de alta resolução espacial de observação da terra
Landsat TM	Landsat Thematic Mapper
QuickBird	Satélite de alta resolução espacial de observação da terra
Nível Temático	Sub-Nível da hierarquia de classes que caracteriza um tema

Anexo 1: Cálculos auxiliares para uma matriz de confusão

Exactidão do utilizador:

$$\text{Classe A} = \frac{25}{32} = 0.7812 \sim 78.1\%$$

$$\text{Classe B} = \frac{39}{46} = 0.8479 \sim 84.4\%$$

$$\text{Classe C} = \frac{45}{50} = 0.90 \sim 90.0\%$$

Omissão:

$$\text{Classe A} = \frac{2 + 5}{50} = 0.2187 \sim 21.9\%$$

$$\text{Classe B} = \frac{6 + 1}{46} = 0.1521 \sim 15.2\%$$

$$\text{Classe C} = \frac{3 + 2}{50} = 0.1 \sim 10.0\%$$

Exactidão do produtor:

$$\text{Classe A} = \frac{25}{34} = 0.7352 \sim 73.5\%$$

$$\text{Classe B} = \frac{39}{43} = 0.9069 \sim 90.7\%$$

$$\text{Classe C} = \frac{45}{51} = 0.8823 \sim 88.2\%$$

Comissão:

$$\text{Classe A} = \frac{6 + 3}{34} = 0.2647 \sim 26.5\%$$

$$\text{Classe B} = \frac{2 + 2}{43} = 0.0930 \sim 9.3\%$$

$$\text{Classe C} = \frac{5 + 1}{51} = 0.1176 \sim 11.8\%$$

Anexo 2: Definição de “OU exclusivo”

Um operador “OU exclusivo” bit-a-bit tem como resultado “0” se os bits comparados forem iguais e “1” se forem diferentes.

Operador “OU exclusivo”		
A	B	Resultado
0	0	0
1	0	1
0	1	1
1	1	0

Tabela 35 - Exemplo do resultado do operador "OU exclusivo"

Anexo 3: Exactidões das melhores classificações do PCN

Nível I	Exactidão do Utilizador	Exactidão do Produtor
Sombra	91,2%	40,5%
Não-Sombra	79,5%	98,3%
Exactidão Global	81,1%	
Índice Kappa	0,462 / Moderado	

Tabela 36 - Nível I - Exactidões do PCN - Classificador MV

Nível II Não-Sombra	Exactidão do Utilizador	Exactidão do Produtor
Vegetação	91,7%	58,3%
Não-Vegetação	77,8%	96,5%
Exactidão Global	81,3%	
Índice Kappa	0,584 / Moderado	

Tabela 37 - Nível II Não-Sombra - Exactidões do PCN - Classificador MAHA

Nível II Não-Vegetação	Exactidão do Utilizador	Exactidão do Produtor
Telhados	64,8%	85,0%
Solo Nu	68,0%	74,0%
Solo Agrícola	65,2%	51,5%
Pavimentos	79,3%	60,0%
Exactidão Global	69,8%	
Índice Kappa	0,550 / Moderado	

Tabela 38 - Nível II Não-Sombra - Exactidões do PCN – Classificador MV

Nível II Vegetação	Exactidão do Utilizador	Exactidão do Produtor
Árvores	63,7%	65,7%
Vegetação Herbácea	70,1%	77,6%
Relva	57,4%	37,1%
Exactidão Global	66,6%	
Índice Kappa	0,435 / Moderado	

Tabela 39 - Nível II Vegetação - Exactidões do PCN – Classificador MV

Nível II Árvores	Exactidão do Utilizador	Exactidão do Produtor
Árvores Claras	67,7%	86,5%
Árvores Escuras	81,8%	59,5%
Exactidão Global	72,9%	
Índice Kappa	0,459 / Moderado	

Tabela 40 - Nível II Árvores - Exactidões do PCN – Classificador MV

Nível II Pavimentos	Exactidão do Utilizador	Exactidão do Produtor
Pavimentos Claros	76,7%	80,6%
Pavimentos Escuros	87,4%	84,6%
Exactidão Global	83,0%	
Índice Kappa	0,645 / Substancial	

Tabela 41 - Nível II Pavimentos - Exactidões do PCN – Classificador MAHA

Nível II Telhados	Exactidão do Utilizador	Exactidão do Produtor
Telha Laranja	91,9%	97,2%
Telhados Claros	93,4%	75,0%
Telhados Médios	71,5%	69,6%
Telhados Escuros	81,6%	46,4%
Exactidão Global	89,5%	
Índice Kappa	0,719 / Substancial	

Tabela 42 - Nível II Telhados - Exactidões do PCN – Classificador MV

Anexo 4: Mapas de referência para os vários níveis temáticos

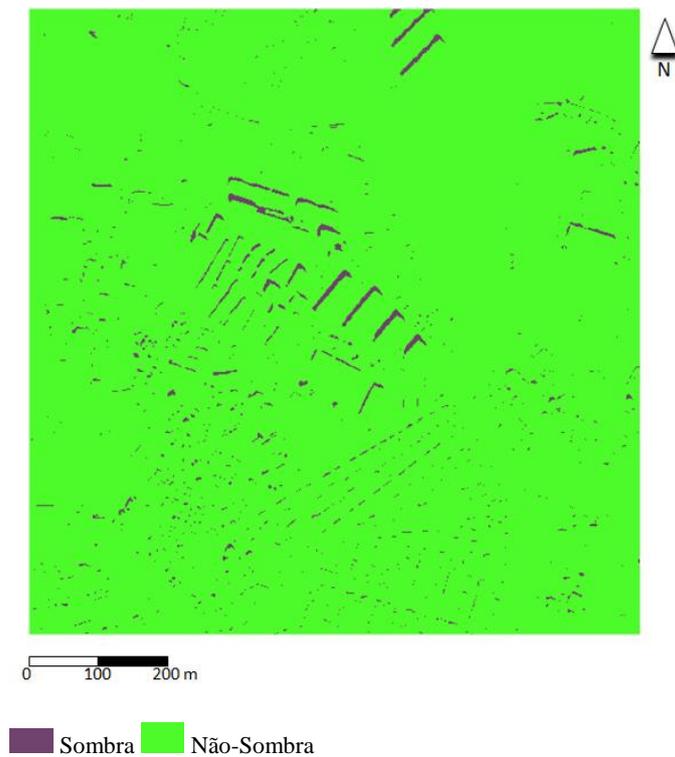


Figura 22 – Mapa de referência para o Nível I

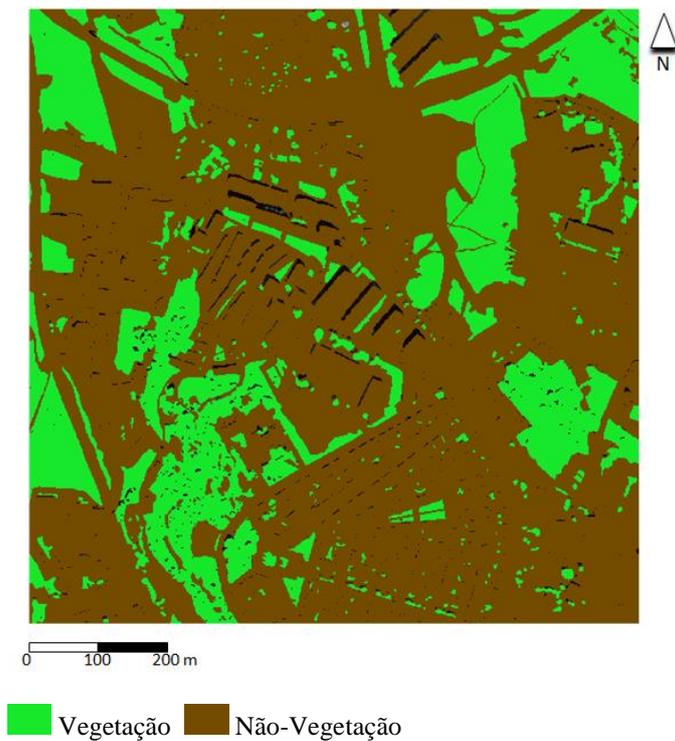
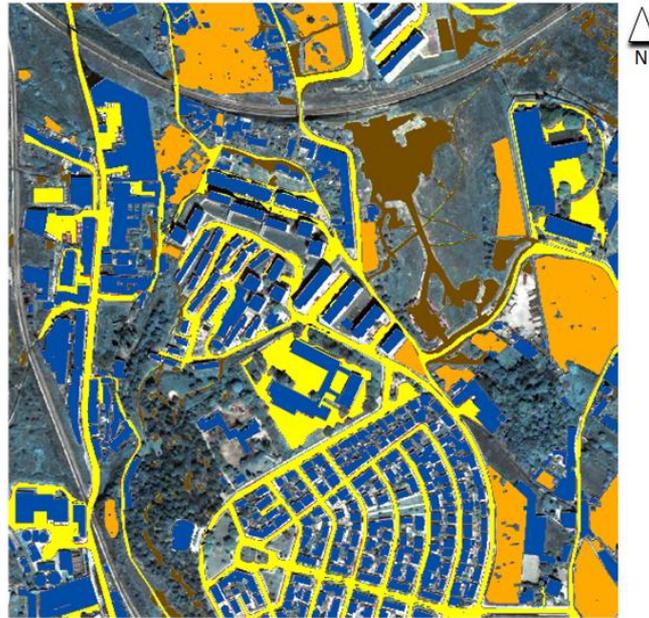


Figura 23 - Mapa de referência para o Nível II Não-Sombra



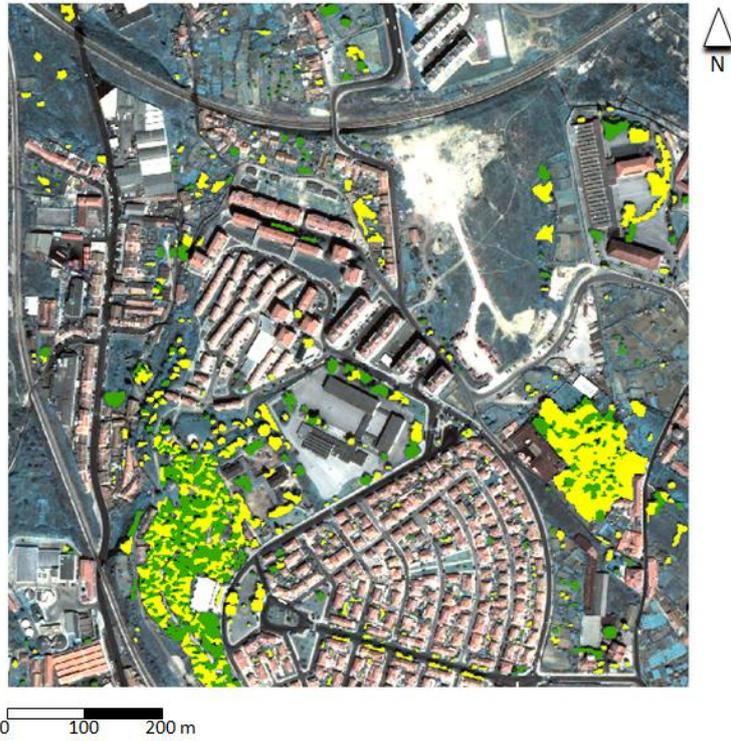
- Telhados
- Pavimentos
- Solo Nu
- Solo Agrícola

Figura 24 - Mapa de referência para o Nível III Não-Vegetação



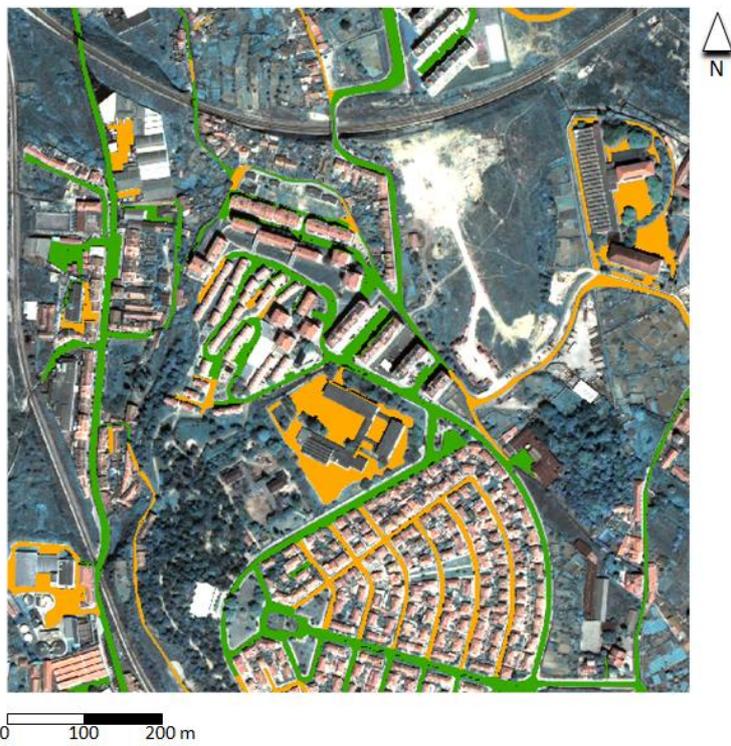
- Árvores
- Relva
- Vegetação Herbácea

Figura 25 - Mapa de referência para o Nível III Vegetação



Árvores Claras
 Árvores Escuras

Figura 26 - Mapa de referência para o Nível IV Árvores



Pavimentos Claros
 Pavimentos Escuros

Figura 27 - Mapa de referência para o Nível IV Pavimentos



0 100 200 m

- | | |
|---|--|
|  Telha Laranja |  Telhados Médios |
|  Telhados Claros |  Telhados Escuros |

Figura 28 - Mapa de referência para o Nível IV Telhados

Anexo 5: Mapas das melhores classificações no Processo de Classificação por Níveis

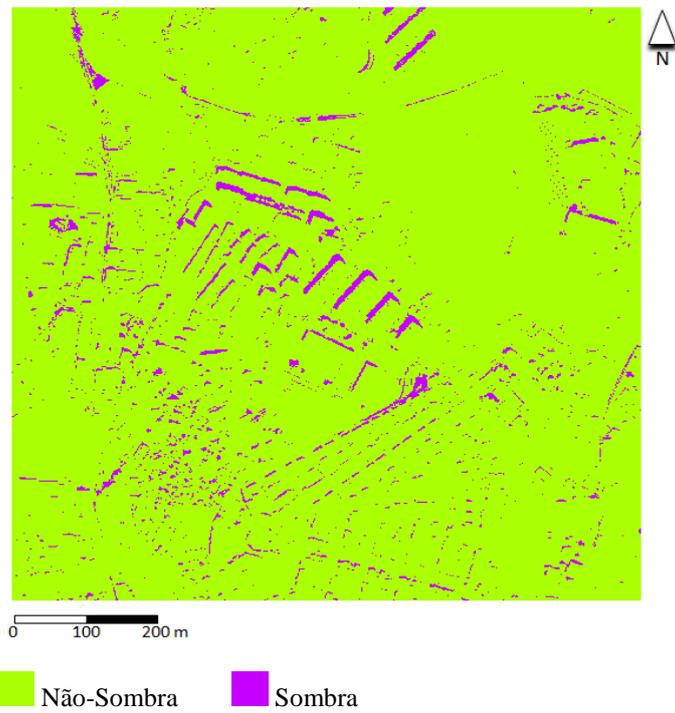


Figura 29 - Nível I - Classificador de Máxima Verossimilhança

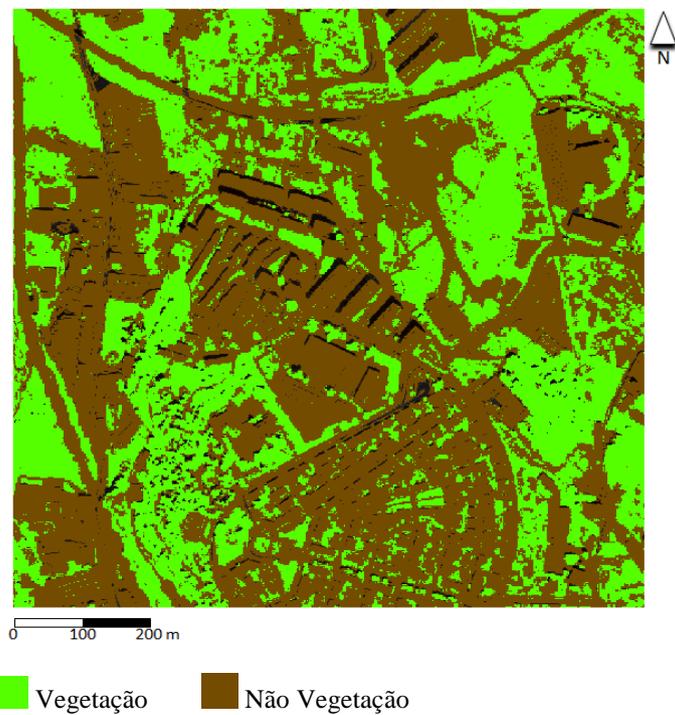


Figura 30 - Nível II - Classificador Distância de Mahalanobis

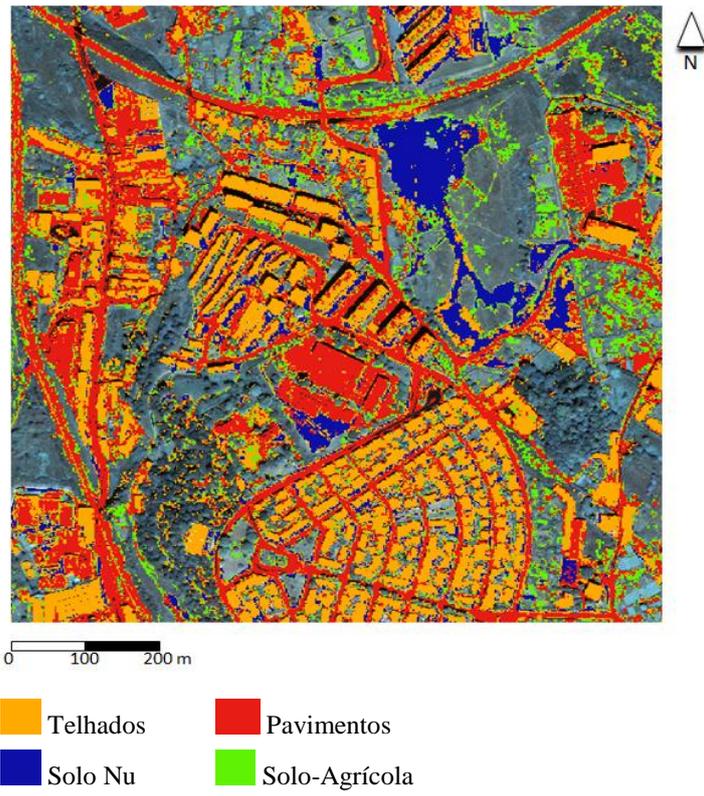


Figura 31 - Nível III Não-Vegetação - Classificador de Máxima Verosimilhança

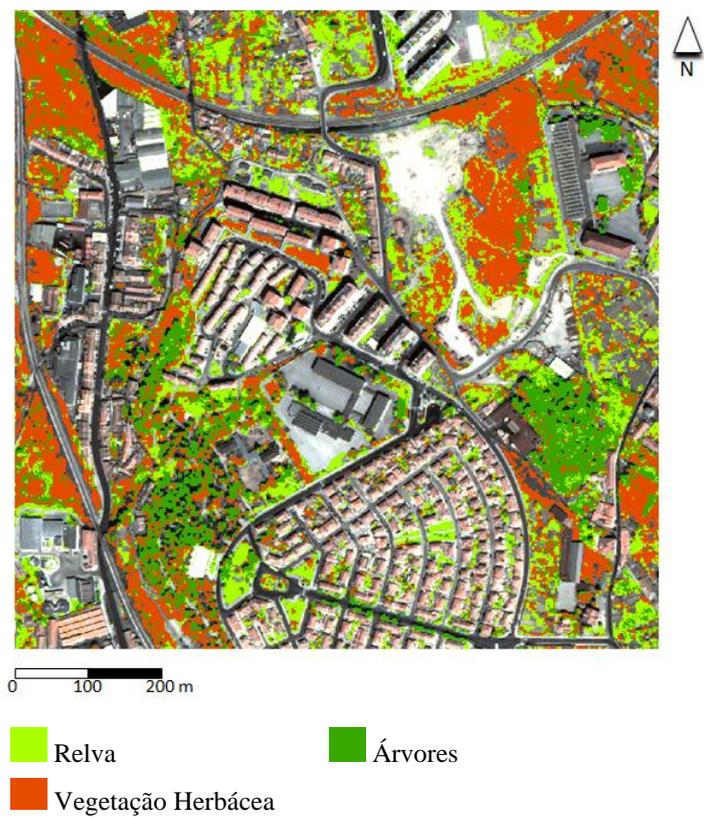


Figura 32 - - Nível III Vegetação - Classificador de Máxima Verosimilhança



0 100 200 m

Árvores Claras Árvores Escuras

Figura 33 - Nível IV Árvores - Classificador de Máxima Verosimilhança



0 100 200 m

Pavimentos Claros Pavimentos Escuros

Figura 34 - Nível IV Árvores - Classificador de Distância Mahalanobis

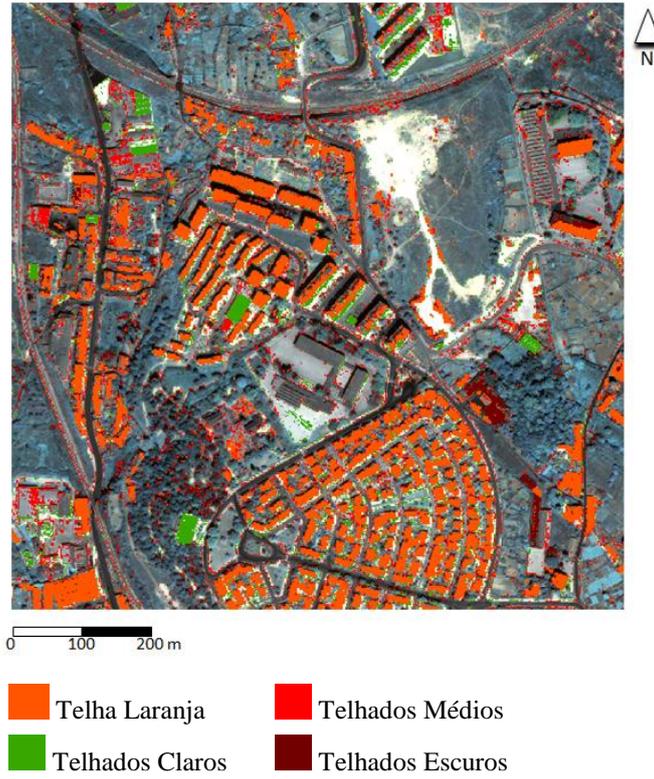


Figura 35 - Nível IV Telhados - Classificador de Máxima Verosimilhança

Anexo 6: Mapas das melhores classificações no Processo de Classificação por Classes

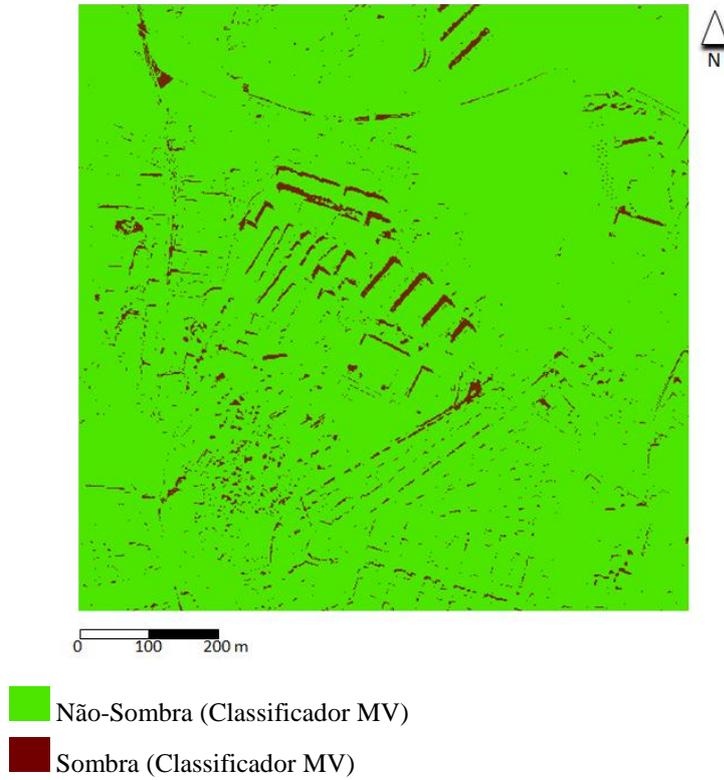
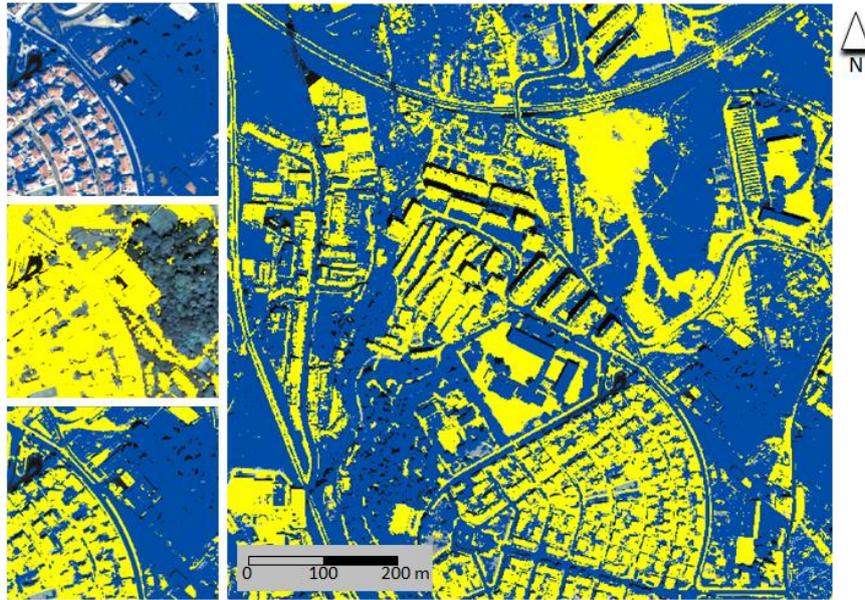
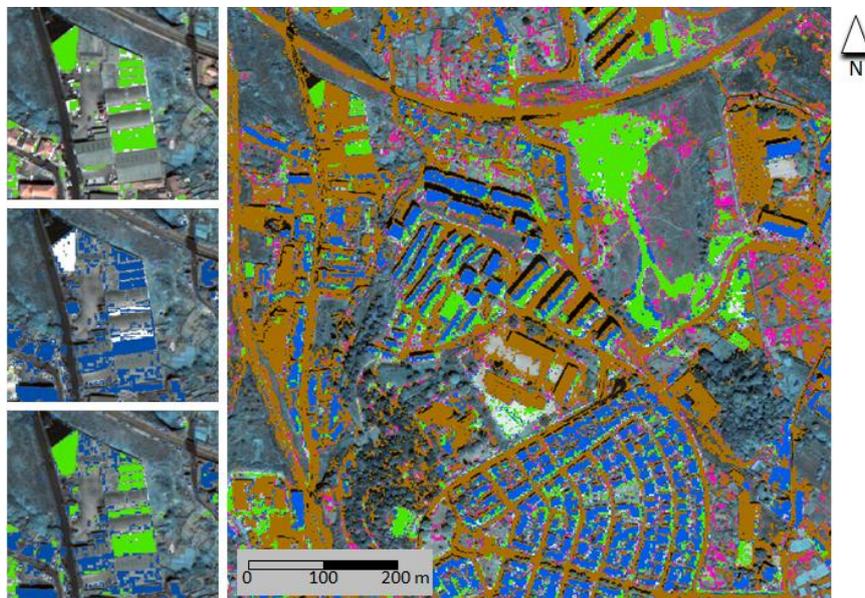


Figura 36 - Nível I - Classificador de Máxima Verossimilhança



- Não-Vegetação (Classificador MAHA)
- Vegetação (Classificador MD)

Figura 37 - Nível II Não-Sombra - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Não-Vegetação; classe Vegetação; resolução da sobreposição). À direita mapa final



- Pavimentos (Classificador MV)
- Solo Agrícola (Classificador MV)
- Solo Nu (Classificador MAHA)
- Telhados (Classificador MV)

Figura 38 - Nível III Não-Vegetação - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Solo Nu; classe Telhados; resolução da sobreposição). À direita mapa final



- Vegetação Herbácea (Classificador MV)
- Relva (Classificador MD)
- Árvores (Classificador MV)

Figura 39 - Nível III Não-Vegetação - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Árvores; classe Relva; resolução da sobreposição). À direita mapa final



- Árvores Claras (Classificador MV)
- Árvores Claras (Classificador MD)

Figura 40 - Nível IV Árvores - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Árvores Claras; classe Árvores Escuros; resolução da sobreposição). À direita mapa final



- Pavimentos Claros(Classificador MV)
- Pavimentos Escuros (Classificador MAHA)

Figura 41- Nível IV Pavimentos - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Pavimentos Claros; classe Pavimentos Escuros; resolução da sobreposição). À direita mapa final



- Telha Laranja (Classificador MV)
- Telhados Médios (Classificador MAHA)
- Telhados Claros (Classificador MV)
- Telhados Escuros (Classificador MAHA)

Figura 42 - Nível IV Telhados - Coluna da esquerda, exemplo de resolução de sobreposição de classes (de cima para baixo: classe Telha Laranja; classe Telhados Escuros; resolução da sobreposição). À direita mapa final

Anexo 7: Mapa da nomenclatura final no Processo de Classificação por Níveis

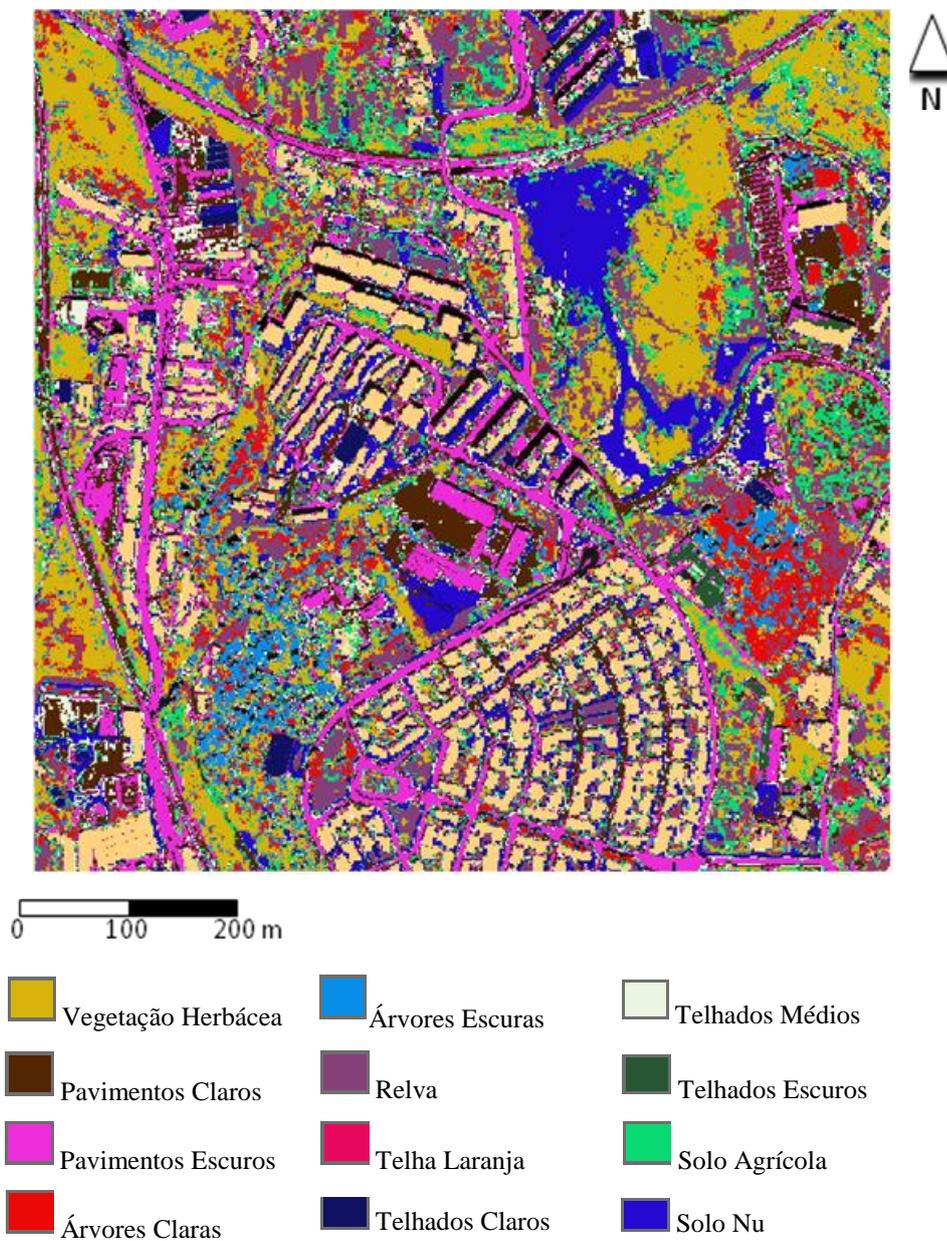


Figura 43 - Mapa final do processo PCN

Anexo 8: Mapa da nomenclatura final no Processo de Classificação por Classes

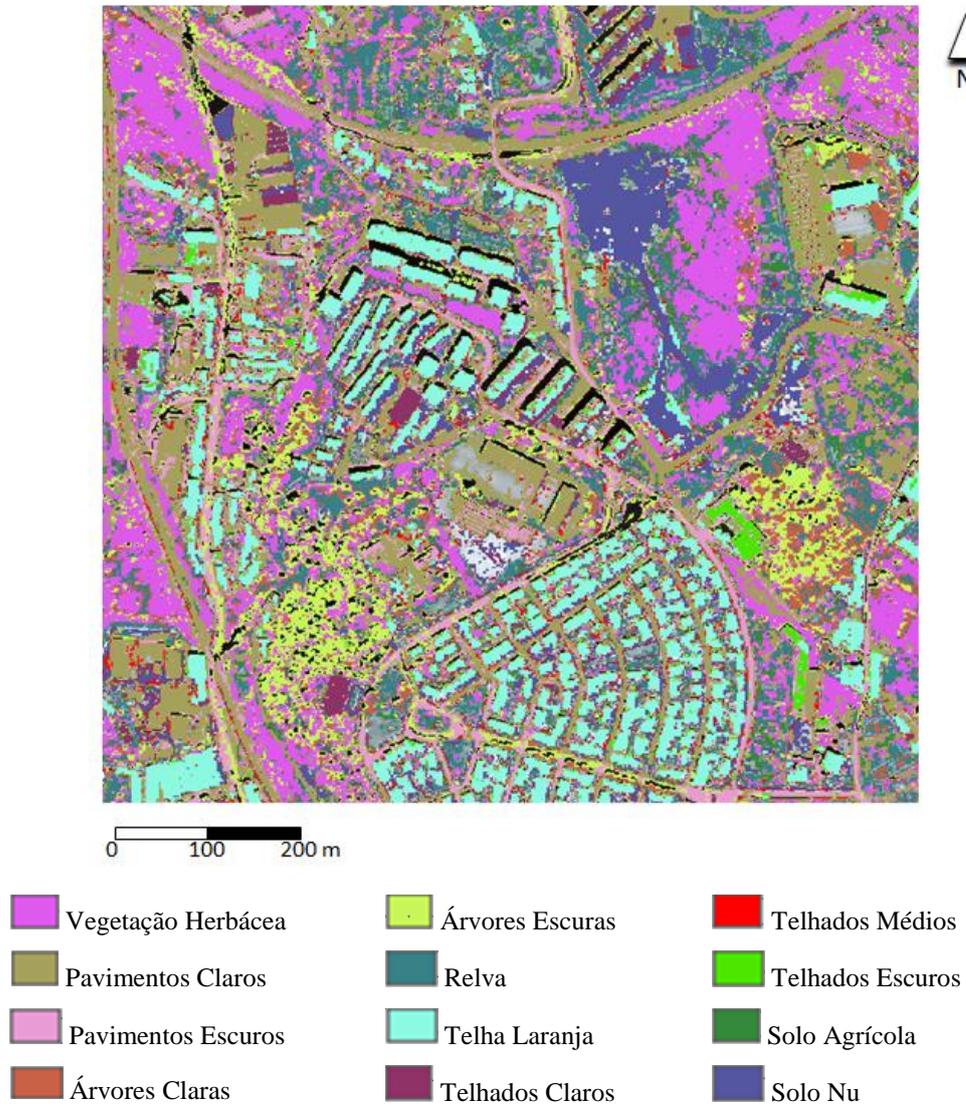


Figura 44 - Mapa final do processo PCC