

UNIVERSIDADE DE LISBOA
FACULDADE DE CIÊNCIAS
DEPARTAMENTO DE ENGENHARIA
GEOGRÁFICA, GEOFÍSICA E ENERGIA



**Utilização de imagens de satélite de alta resolução para a
extracção de elementos em ambiente urbano**

Nuno Miguel Nogueira Martins

Dissertação

Mestrado em Engenharia Geográfica

2012

UNIVERSIDADE DE LISBOA
FACULDADE DE CIÊNCIAS
DEPARTAMENTO DE ENGENHARIA
GEOGRÁFICA, GEOFÍSICA E ENERGIA



**Utilização de imagens de satélite de alta resolução para a
extracção de elementos em ambiente urbano**

Nuno Miguel Nogueira Martins

Dissertação orientada pela Professora Doutora Ana Cristina Navarro
Ferreira

Mestrado em Engenharia Geográfica

2012

Agradecimentos

O desenvolvimento deste trabalho deve-se à supervisão da Professora Ana Cristina Navarro Ferreira que deu a sua orientação e conhecimento científico, ajudando assim em todos os momentos chaves.

Outro contributo relevante que se regista é o do Professor João Carlos da Costa Catalão Fernandes que se apresentou sempre disponível para dúvidas relacionadas com o trabalho.

Em termos dos dados utilizados no trabalho, foram fornecidos pela e-GEO, Centro de Estudos de Geografia e Planeamento Regional, da Faculdade de Ciências Sociais e Humanas (FCSH), sendo de realçar a atenção dispensada pelo senhor Sérgio Freire que transferiu e explicou todo o tipo de dados disponíveis.

Outras pessoas apoiaram e contribuíram apresentando sugestões, onde o apoio desses colegas e familiares foi fundamental.

Resumo

Pretende-se, com a elaboração desta dissertação, explorar o potencial das imagens do satélite WorldView-2 para a extração de elementos em ambiente urbano em comparação com os resultados obtidos com outras imagens de muito alta resolução espacial, tais como as dos satélites QuickBird e Ikonos. Para tal, foi realizado um estudo comparativo recorrendo à utilização de diversos métodos de classificação supervisionada e não-supervisionada de imagens satélite, os quais se baseiam apenas nas características espectrais das imagens e também à construção de árvores de decisão, utilizando índices de vegetação e um modelo digital de superfície normalizado da área de estudo. Neste trabalho, os resultados obtidos no método de classificação de árvores de decisão foram mais precisos porque apenas neste método é que foram utilizados os respetivos dados auxiliares. As principais dificuldades encontradas na execução deste trabalho estão relacionados com os erros de classificação resultantes das características complexas dos ambientes urbanos, sendo que a existência de sombras e de rebatimentos nas estruturas mais elevadas correspondem também a limitações deste tipo de imagens. Neste estudo verificou-se que, para a imagem do WorldView-2, a aplicação da árvore de decisão foi onde se obteve os melhores resultados (na ordem dos 90% de exatidão global). Por outro lado, os resultados obtidos com a aplicação de algoritmos de classificação supervisionada não permitiram concluir qual a imagem que apresenta os melhores resultados, uma vez que a imagem do WorldView-2 foi a que apresentou melhores resultados no método de classificação da máxima verossimilhança (96% de exatidão global) e a imagem do QuickBird foi a que apresentou melhores resultados no método da distância de Mahalanobis (na ordem dos 74% de exatidão global). De realçar que as três imagens obtiveram os melhores resultados no método da máxima verossimilhança (na ordem dos 95% de exatidão global, na imagem do QuickBird, 84% de exatidão global, na imagem do Ikonos e 96% de exatidão global, na imagem do WorldView-2), sendo a imagem do Ikonos a que apresentou os piores resultados, comparando com as outras imagens, em todos os métodos de classificação utilizados. A dissertação está escrita de acordo com o novo acordo ortográfico.

Abstract

The purpose of this thesis is to explore the potential of satellite images WorldView-2 for the extraction of elements in an urban environment compared with the results obtained with other images of very high spatial resolution, such as QuickBird and Ikonos satellites. To this end, a comparative study was conducted by the use of several methods of supervised and unsupervised classification satellite images, which are based only on the spectral characteristics of the images and also the construction of decision trees, using vegetation index images and a normalized digital surface model of the study area. In this work, the results obtained in the method of classification decision trees were more accurate because only is this method that was used the respective auxiliary data. The main difficulties encountered in implementing this work are related to classification errors resulting from complex characteristics of urban environments, and the existence of shadows and higher repercussions structures correspond also to the limitations of this type of images. In this study it was found that, to WorldView-2 image, the application of the decision tree was where obtained the best results (around 90% global accuracy). Moreover, the results obtained with the application of supervised classification algorithms do not allow to conclude that the image gives the best results, since the image of WorldView-2 showed the best results in the method of maximum likelihood classification (96% global accuracy) and QuickBird image showed the best results in the method of Mahalanobis distance (around 74% global accuracy). Note that the three images obtained the best results in the maximum likelihood method (around 95% of global accuracy, the image of QuickBird, 84% of global accuracy, the Ikonos image and 96% of global accuracy, the image of WorldView-2) and the image Ikonos presented the worse results compared to the other images in all the methods of sorting used. The dissertation is written according to the new agreement spelling.

Índice

Lista de figuras.....	vii
Lista de tabelas.....	ix
Lista de abreviaturas	xi
Palavras-chave	xii
1. Introdução	1
1.1. Enquadramento.....	1
1.2. Motivação	2
1.3. Objetivos	3
1.4. Resultados esperados	3
2. Estado da arte.....	4
3. Fundamentos teóricos	8
3.1. Classificação das imagens satélite	8
3.1.1. Classificação Não-Supervisionada.....	10
3.1.1.1. Método ISODATA.....	11
3.1.1.2. Método K-MEANS	11
3.1.2. Classificação Supervisionada	11
3.1.2.1. Método do paralelepípedo	12
3.1.2.2. Método da distância mínima.....	14
3.1.2.3. Método da distância de Mahalanobis	16
3.1.2.4. Método da máxima verossimilhança.....	16
3.1.2.5. Método <i>Spectral Angle Mapper</i>	19
3.1.2.6. Método <i>Spectral Information Divergence</i>	21
3.1.2.7. Método de codificação binária.....	21
3.1.3. Árvores de Decisão	22
3.2. Comparação e verificação dos resultados das classificações	23
3.2.1. Matriz de confusão ou de erros (Confusion Matrix ou Error Matrix).....	24
3.2.2. Índice de concordância Kappa.....	26
4. Dados e metodologia utilizada	29
4.1. Área de estudo	29
4.2. Dados utilizados	30
4.2.1. Imagens satélite	30

Mestrado em Engenharia Geográfica

Departamento de Engenharia Geográfica, Geofísica e Energia

Faculdade de Ciências da Universidade de Lisboa

4.2.2.	Metadados	31
4.2.3.	Modelo Digital de Superfície normalizado	32
4.2.4.	Índices de Vegetação	33
4.3.	Metodologia	34
5.	Resultados e discussão.....	42
5.1.	Resultados obtidos	42
5.1.1.	Classificação não-supervisionada	42
5.1.1.1.	Método ISODATA.....	42
5.1.1.2.	Método K-MEANS	44
5.1.2.	Classificação supervisionada	47
5.1.2.1.	Método do paralelepípedo	47
5.1.2.2.	Método da distância mínima.....	49
5.1.2.3.	Método da distância de Mahalanobis	52
5.1.2.4.	Método da máxima verossimilhança.....	54
5.1.2.5.	Método <i>Spectral Angle Mapper</i>	58
5.1.2.6.	Método <i>Spectral Information Divergence</i>	60
5.1.2.7.	Método de codificação binária.....	62
5.1.3.	Árvores de decisão.....	65
5.2.	Discussão e análise	69
6.	Conclusões	72
7.	Referências bibliográficas	74

Lista de figuras

Figura 3.1 – Histograma para os componentes bidimensionais da informação espectral de uma área de treino.

Figura 3.2 – Esquema do método de classificação do paralelepípedo.

Figura 3.3 – Exemplo de inseparabilidade resultante do classificador paralelepípedo.

Figura 3.4 – Esquema do método de classificação da distância mínima.

Figura 3.5 – Exemplo de duas amostras espectrais com o mesmo centróide mas com diferentes dispersões.

Figura 3.6 – Esquema do método de classificação da distância de Mahalanobis.

Figura 3.7 – Esquema do método de classificação da máxima verossimilhança.

Figura 3.8 – Exemplo do método SAM bidimensional.

Figura 3.9 – Exemplo de dois elementos com o mesmo ângulo e magnitudes diferentes na imagem mais à esquerda e dois elementos com ângulos diferentes e magnitudes diferentes na imagem mais à direita.

Figura 3.10 – Estrutura de uma árvore de decisão.

Figura 3.11 – Exemplo de um caminho da classificação de uma árvore de decisão.

Figura 4.1 – Localização da área de estudo no concelho de Lisboa.

Figura 4.2 – Diferença entre o DTM e o DSM.

Figura 4.3 – nDSM da área de estudo.

Figura 4.4 – Cortes das imagens do QB, IK e WV-2, respetivamente.

Figura 4.5 – Áreas de referência das imagens do QB, do IK e do WV-2, respetivamente.

Figura 4.6 – Áreas de treino da imagem do QB, do IK e do WV-2, respetivamente.

Figura 4.7 – Imagens dos índices NDVI e bNDVI do WV-2.

Figura 4.8 – Estrutura da árvore de decisão da imagem do WV-2.

Figura 5.1 – Imagem do WV-2 classificada pelo método ISODATA.

Figura 5.2 – Imagem do WV-2 classificada pelo método K-MEANS.

Figura 5.3 – Imagem do QB classificada pelo método do paralelepípedo.

Figura 5.4 – Imagem do QB classificada pelo método da distância mínima.

Figura 5.5 – Imagem do QB classificada pelo método da distância de Mahalanobis.

Figura 5.6 – Imagem do WV-2 classificada pelo método da máxima verossimilhança.

Figura 5.7 – Imagem do QB classificada pelo método SAM.

Figura 5.8 – Imagem do WV-2 classificada pelo método SID.

Figura 5.9 – Imagem do WV-2 classificada pelo método de codificação binária.

Figura 5.10 – Imagem do WV-2 classificada pelo método da árvore de decisão.

Lista de tabelas

Tabela 3.1 – Exemplo do resultado do operador “OU exclusivo”.

Tabela 3.2 – Exemplo de uma Matriz de confusão.

Tabela 3.3 – Medidas de concordância do Índice Kappa.

Tabela 3.4 – Matriz de confusão anterior modificada.

Tabela 4.1 – Resoluções dos satélites QB, IK e WV-2.

Tabela 4.2 – Metadados das imagens do QB, IK e WV-2.

Tabela 5.1 – Tabela das exatidões globais e índices Kappa obtidos no método ISODATA das três imagens.

Tabela 5.2 – Tabela das exatidões globais e índices Kappa obtidos no método K-MEANS das três imagens.

Tabela 5.3 – Tabela das exatidões globais e índices Kappa obtidos no método do paralelepípedo das três imagens.

Tabela 5.4 – Tabela das exatidões globais e índices Kappa obtidos no método da distância mínima das três imagens.

Tabela 5.5 – Tabela das exatidões globais e índices Kappa obtidos no método da distância de Mahalanobis das três imagens.

Tabela 5.6 – Tabela das exatidões globais e índices Kappa obtidos no método da máxima verossimilhança das três imagens.

Tabela 5.7 – Matriz de confusão obtida no método da máxima verossimilhança da imagem do QB.

Tabela 5.8 – Matriz de confusão obtida no método da máxima verossimilhança da imagem do WV-2.

Tabela 5.9 – Tabela das exatidões globais e índices Kappa obtidos no método SAM das três imagens.

Tabela 5.10 – Tabela das exatidões globais e índices Kappa obtidos no método SID das três imagens.

Tabela 5.11 – Tabela das exatidões globais e índices Kappa obtidos no método de codificação binária das três imagens.

Tabela 5.12 – Tabela das exatidões globais e índices Kappa obtidos no método de árvores de decisão das três imagens.

Tabela 5.13 – Matriz de confusão obtida no método da árvore de decisão da imagem do QB.

Tabela 5.14 – Matriz de confusão obtida no método da árvore de decisão da imagem do WV-2.

Tabela 5.15 – Exatidões globais obtidas nas classificações não-supervisionadas.

Tabela 5.16 – Exatidões globais obtidas nas classificações supervisionadas.

Lista de abreviaturas

W – Oeste

N – Norte

ha – Hectares

km – Quilómetros

km² – Quilómetros quadrados

µm – micrómetros (10⁻⁶ metros)

QB – QuickBird

IK – Ikonos

WV-2 – WorldView-2

DTM – Digital Terrain Model

DSM – Digital Surface Model

nDSM – normalized Digital Surface model

CCD – Charge Coupled Device

CMGs – Control Moment Gyroscopes

IV – Infravermelho

Maxver – Máxima verossimilhança

SAM – Spectral Angle Mapper

SID – Spectral Information Divergence

NDVI – Normalized Difference Vegetation Index

bNDVI – blue Normalized Difference Vegetation Index

IAF – Índice de Área Foliar

Palavras-chave

QuickBird

Ikonos

WorldView-2

Imagens satélite

Modelo digital de superfície normalizado

Classificação não-supervisionada

Classificação supervisionada

Índices de vegetação

Árvores de decisão

Matriz de confusão

Mestrado em Engenharia Geográfica

Departamento de Engenharia Geográfica, Geofísica e Energia

Faculdade de Ciências da Universidade de Lisboa

1. Introdução

Neste primeiro capítulo será explicado de forma introdutória o enquadramento do trabalho, onde será descrita a sua estrutura e conteúdos, a motivação, onde será referido os seus principais contributos, os objetivos, onde será mencionado a principal finalidade da sua execução e, por último, os resultados esperados no trabalho, onde será indicado os resultados que se espera obter.

1.1. Enquadramento

Este trabalho enquadra-se no projeto de investigação “GeoSAT – Metodologias para extração de informação GEOgráfica a grande escala a partir de imagens de SATélite de alta resolução” do e-GEO (Centro de Estudos de Geografia e Planeamento Regional). Este projeto, que envolve a Câmara Municipal de Lisboa, tem como objetivo o desenvolvimento de métodos que acelere a produção de informação geográfica para o planeamento municipal, a representação de objetos e a investigação do potencial das imagens de satélite de alta resolução para deteção e mapeamento de elementos urbanos, integrando-as no planeamento urbano operacional e nas atividades de gestão (Freire *et al.*, 2010).

Em termos da estrutura do trabalho, primeiro será explicado de forma sucinta o estado da arte do tema da classificação de imagens satélite de muito alta resolução, mencionando a sua importância e principais limitações, descrito todos os fundamentos teóricos dos métodos de classificação, dos índices de vegetação e dos critérios de comparação e verificação dos resultados utilizados no trabalho e, também serão indicados os dados e metodologia utilizada para a sua respetiva execução. Nesta fase dos dados e metodologia utilizada no trabalho será indicada a localização da respetiva área de estudo, as imagens de satélite e modelo digital de superfície normalizado utilizados para a execução dos métodos de classificação e, por fim, será descrito pormenorizadamente todos os passos da execução deste trabalho. De seguida serão demonstrados e discutidos todos os resultados obtidos nos métodos de classificação de imagens através da exibição das respetivas matrizes de confusão obtidas e da imagem classificada que obteve o melhor resultado.

Demonstrados todos os resultados obtidos, estes serão discutidos e analisados de forma a poder-se tirar as devidas conclusões do trabalho. Estas conclusões serão mencionadas de seguida, sendo esta a ultima fase deste trabalho.

1.2. Motivação

A principal motivação para a execução deste trabalho foi o facto deste tema ainda ser demasiado complexo, pois, apesar de se encontrar em constante evolução, ainda se depara com muitos problemas e limitações. Nestes problemas e limitações, realça-se a dificuldade das classificações das zonas urbanas devido a uma excessiva quantidade de elementos com alturas significativas provocando assim sombras e arrastamento nas imagens, sendo estas os principais obstáculos para uma correta classificação de imagens. Outro fator motivador na escolha deste trabalho foi o gosto e interesse pelas imagens satélite e por o que elas permitem realizar através das suas análises.

Este trabalho teve o principal contributo do e-GEO por disponibilizarem todos os dados necessários para a sua execução, sendo eles as respetivas imagens do WV-2, IK e QB e os dados altimétricos da zona de Lisboa. De realçar que este contributo foi importante porque também disponibilizaram os respetivos dados já devidamente tratados, isto é, as imagens satélite já se encontravam com a junção das imagens pancromática e multiespectral, que é efetuado através da função Pansharping e os dados altimétricos já tinham o respetivo modelo digital de superfície normalizado calculado, que é determinado através da diferença do modelo digital do terreno com o modelo digital de superfície, podendo assim obter as respetivas alturas dos elementos da imagem.

1.3. Objetivos

O principal objetivo deste trabalho consiste na verificação das melhorias que as imagens do novo satélite WV-2 apresentam na extração de elementos em espaço urbano, pois a imagem que será utilizada neste trabalho, apesar de ter sido adquirida em 2010, ainda não foi processada nem analisada, não tendo assim conhecimento dos seus benefícios espectrais. Para a respetiva verificação das melhorias da imagem do WV-2, esta será comparada com as imagens do QB e do IK através da execução de vários algoritmos de classificação supervisionada e não-supervisionada de imagens bem como a classificação por árvores de decisão. Serão também executados alguns índices de vegetação para que se possa conhecer melhor o comportamento da área de estudo, podendo assim melhorar as respetivas classificações das árvores de decisão.

1.4. Resultados esperados

Os resultados esperados são a respetiva confirmação da melhoria que as imagens do novo satélite WV-2 apresentam na extração de elementos em espaço urbano. Em termos espectrais espera-se uma melhoria devido à existência de três novas bandas no WV-2, sendo elas o azul costal, o amarelo e o vermelho borda. Outro aspeto que se espera que melhore os resultados finais é a resolução espacial do WV-2, sendo esta 0.5 metros para a imagem pancromática e 1.8 metros para a imagem multiespectral.

Nas classificações supervisionadas e não-supervisionadas, os resultados dependem muito da parte espectral da imagem, sendo de esperar que a imagem do WV-2 obtenha o melhor resultado. No caso das árvores de decisão, os resultados não dependem só da parte espectral da imagem mas também da qualidade dos outros dados utilizados, como os dos índices de vegetação e do modelo digital do terreno, sendo assim de esperar um bom resultado em todas as imagens.

2. Estado da arte

A Detecção Remota é uma ciência, uma técnica e uma tecnologia ao serviço da observação da Terra e, em particular, das cidades, sendo estas caracterizadas por uma ampla gama de respostas espectrais. Estas respostas espectrais só fazem sentido quando combinadas com o conteúdo temático, sendo interpretado com base na forma e morfologia dos diferentes elementos que estão incluídos em ambiente urbano (Santos *et al.*, 2010). Estes ambientes urbanos são muito complexos porque misturam diversas características de elementos que podem gerar uma relação confusa entre o objeto e seu espectro, como por exemplo, objetos diferentes podem ter o mesmo espectro ou os mesmos objetos podem ter o espectro diferente (Chen *et al.*, 2009).

A extração de informação geográfica em grande escala de imagens satélite de alta resolução é muito importante nos estudos das zonas urbanas, especialmente em áreas com uma elevada taxa de alterações, podendo desta forma atualizar a respetiva informação geográfica. Esta mudança constante do ambiente urbano tornou-se o interesse de pesquisadores para aplicações de deteção remota de áreas rurais para urbanas.

Numerosas técnicas de deteção de alterações são aplicadas em imagens de datas diferentes, a fim de detetar as mudanças ocorridas ao longo dos anos. Estas técnicas são divididas em duas categorias gerais, sendo elas métodos de pré-classificação e de pós-classificação. As técnicas de pré-classificação são aplicadas sobre imagens corrigidas retificadas e normalizadas (por exemplo, álgebra de imagens, índices, transformações, entre outros) e detetam a possível posição das mudanças sem fornecer qualquer informação para o tipo de alteração da cobertura do solo. Por outro lado, as técnicas de pós-classificação baseiam-se na comparação de imagens classificadas e fornecem informação pormenorizada sobre a natureza da alteração (como por exemplo, de vegetação para urbano) para cada pixel ou objeto (Doxani *et al.*, 2008).

Uma das principais finalidades na utilização de imagens de satélite de alta resolução é 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 exata das imagens provenientes desses sensores (Crisógono, 2011).

Os recentes sensores de satélite de muito alta resolução fornecem imagens equivalentes aos produtos ortofoto, sendo assim muito boas para utilizar na extração de elementos de cobertura do solo em ambientes urbanos. O procedimento mais comum para obter mapas temáticos a partir destas imagens é a utilização de classificadores baseados em píxeis, mas no entanto, nenhuma técnica operacional nas emendas ao nível do pixel satisfaz todas as necessidades para uma produção de mapas precisos e confiáveis. Recentemente, os classificadores que operam ao nível do objeto, em vez do pixel, foram desenvolvidos, tendo sido proposto um algoritmo de segmentação, em que se utiliza a técnica de uma região de cultivo para criar segmentos de imagem com base em quatro critérios: a escala, a cor, a suavidade e a compacidade. Os elementos da imagem são então classificados em classes temáticas, com base em amostras de objetos (áreas de treino) ou de acordo com descrições de classes organizadas em uma base de conhecimento apropriado. A base de conhecimento em si é criada por meio de mecanismos de herança, conceitos e métodos de lógica e modelagem semântica (Soares *et al.*, 2010).

As técnicas de processamento digital de imagens permitem tratar os dados e gerar parâmetros adicionais aos métodos convencionais de pesquisa. Dentre estas, a classificação de imagens que atribui cada pixel da imagem a uma dada classe, a fim de reconhecer padrões e objetos para representar nas áreas de interesse. Cada pixel apresenta um valor numérico que representa a reflectância dos objetos que o compõem. Como produto final tem-se um mapa temático, o qual representa a distribuição geográfica das classes.

O desempenho da classificação depende da capacidade de reconhecer as feições e da experiência do intérprete com a área de estudo, porém, qualquer tipo de classificação está sujeita a erros. Uma vez que o método simplifica a complexidade da imagem, muitas vezes as classes predefinidas são incompletas e apenas as características espectrais são consideradas, deixando de lado as texturais (Silva e Pereira, 2007).

Embora existam muitos estudos focados nos métodos automáticos de extração de elemento, ainda existem limitações relativas à eficácia destes métodos, especialmente se tiver como objetivo aplicador sobre uma paisagem global contendo várias classes de objetos que contêm também diferentes representações radiométricas.

A disponibilidade de imagens adquiridas pela atual geração de satélites com sensores de alta resolução contribuiu para novas aplicações, especialmente para mapas detalhados de áreas urbanas em grandes escalas. Estas imagens de alta resolução, bem como os métodos inovadores de seu processo contribuíram para muitos estudos urbanos integrados, sendo a questão principal destes estudos a representação dos tipos de cobertura terrestre em ambiente urbano. As tradicionais técnicas de classificação de pixéis revelaram-se inconveniente para a análise de imagens de alta resolução, tendo muitos pesquisadores, recentemente, como por exemplo Moeller e Hofmann, adaptando o conceito inovador de análise orientada a objetos, tratando objetos significativos, em vez de pixéis. Embora a sua resolução espacial permita a identificação de objetos urbanos e suburbanos, estas imagens são difíceis de classificar, numa base pixel-a-pixel, devido ao seu elevado nível de informação. As imagens de áreas urbanas contêm um conjunto espacial complexo de tipos de terreno espectralmente distintos, que requerem informação espacial/semântica importante para a sua classificação. Nestes casos, os algoritmos de classificação de imagens orientados a objetos são recomendados porque as informações necessárias para interpretar essas imagens é representada por objetos da imagem e as suas relações mútuas (Dinis *et al.*, 2010).

Contudo, estes satélites estão limitados a 4 bandas espectrais, sendo que 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 falsas de certos elementos. Estas falsas classificações podem ser atenuadas na utilização do satélite WorldView-2, pois este contém 8 bandas espectrais, resolvendo assim alguns problemas na classificação de elementos que se encontrem perto da fronteira do espectro. Uma forma de diminuir esta desvantagem, consiste na utilização de informação complementar como a textura, a forma, ou o contexto espacial, que pode ser incorporada nas classificações de imagens de alta resolução (Crisógono, 2011).

Outra limitação da utilização de imagens de alta resolução espacial está relacionada com a existência de sombras projetadas pelos elevados objetos urbanos, em particular de edifícios. Estas áreas sombreadas normalmente são deixadas sem classificação ou simplesmente classificadas como sombras, resultando numa perda significativa de informações características do terreno. Uma abordagem possível para superar este problema é a utilização de informação espacial, como as relações adjacência, para a classificação de áreas sombreadas neste tipo de imagens (Dinis *et al.*, 2010). Os algoritmos de classificação de objetos orientados consideram não só a informação espectral mas também várias outras características do objeto, tais como a forma, a textura e o contexto espacial, podendo ser utilizados para melhorar a classificação em áreas urbanas. Alternativamente, as sombras podem ser classificadas através da substituição dos pixels sombreados por pixels não sombreados da mesma região de outra imagem adquirida numa altura diferente ou com diferentes ângulos de azimute (Zhou *et al.*, 2009).

Existem dados relevantes que melhoram a classificação de imagens, sendo um deles os dados altimétricos que auxiliam a classificação através da discriminação dos objetos que se encontrem em alturas diferentes. No entanto, estes dados em si podem não ser suficientes para distinguir entre os diferentes objetos que se encontrem com uma mesma altitude, como é o caso de edifícios e de árvores. Nestes casos, os índices de vegetação espectrais, tais como o NDVI, pode ser uma mais-valia na classificação, pois a sua utilização irá discriminar vegetação das superfícies impermeáveis.

3. Fundamentos teóricos

Neste capítulo serão explicados, de forma sucinta, o funcionamento de todos os algoritmos de classificação não-supervisionadas, supervisionadas e de árvores de decisão utilizados, como é obtida a matriz de confusão e o índice de concordância Kappa das classificações para a verificação e comparação dos resultados e, por último, como se determinam os índices de vegetação que serão posteriormente utilizados na classificação das árvores de decisão.

3.1. Classificação das imagens satélite

A classificação de imagens consiste na identificação de tipos de cobertura de solo, de acordo com os padrões de resposta espectral dos elementos.

Os métodos de análise de dados, designados de reconhecimento ou de classificação de padrões, têm como objetivo classificar um conjunto de dados em função de um conjunto de elementos padrão. A análise divide-se em duas partes distintas:

- Definição do conjunto de elementos padrão;
- Classificação dos dados em função da sua comparação com os elementos padrão, utilizando uma regra de classificação ou função discriminante;

Na fase do estabelecimento do conjunto de padrões, são estabelecidas as propriedades estatísticas de conjuntos de elementos padrão, à custa das quais os elementos da imagem vão ser classificados. No reconhecimento de classes de ocupação do solo em imagens de deteção remota, os padrões são as assinaturas espectrais das classes a identificar na imagem. Um determinado tipo de ocupação do solo pode ser caracterizado por uma única assinatura espectral. No entanto, diversos fatores, tais como a influência da atmosfera, a topografia e o tipo de solo coberto fazem com que um determinado tema de ocupação do solo seja caracterizado por um conjunto de valores de assinaturas espectrais, podendo esses fatores serem considerados como fontes de erros aleatórios.

Os classificadores podem ser divididos em classificadores pixel a pixel e classificadores por regiões.

Os classificadores pixel a pixel utilizam apenas a informação espectral de cada pixel para achar regiões homogéneas. Estes classificadores podem ser separados em métodos estatísticos (utilizam regras da teoria de probabilidade) e determinísticos (não utilizam probabilidade);

Os classificadores por regiões utilizam, além de informação espectral de cada pixel, a informação espacial que envolve a relação com seus vizinhos. Procuram simular o processo de foto-interpretação, reconhecendo áreas homogéneas de imagens, baseados nas propriedades espectrais e espaciais de imagens.

A classificação pode ser feita de dois métodos:

- Classificação não-supervisionada (unsupervised) – é feita uma segmentação da imagem (classificação automática) através de um algoritmo e de seguida são agregadas e atribuídas classes da nomenclatura em uso através do utilizador;
- Classificação supervisionada (supervised) – é definida áreas de treino de acordo com a nomenclatura em uso através de atribuição de classes pelo utilizador e de seguida é feita uma classificação automática da imagem através de um algoritmo.

Uma etapa vital no processo de classificação é a avaliação da exatidão das imagens finais produzidas. Para uma mesma imagem, em ambos os métodos de classificação, é provável obter diferentes padrões de classificação em função dos critérios utilizados para a sua seleção, tais com diferentes algoritmos de aglomeração e diferentes seleções de áreas de treino. Por este motivo é necessário utilizar critérios para avaliar a qualidade das imagens obtidas.

A classificação de objetos ou fenómenos é feita pela escolha das características que os descrevem para diferenciá-los entre si. Na definição matemática, usa-se o espaço de atributos (“feature space”), que é essencial para se entender como funciona a classificação de imagens multiespectrais. No processamento digital, a cada eixo desse espaço são atribuídos os níveis de cinza de uma determinada banda espectral.

Os métodos de classificação dividem-se basicamente em duas categorias: a classificação supervisionada e a não-supervisionada. Nesta segunda não há qualquer conhecimento prévio do classificador sobre os atributos das classes pertinentes da área de estudo, enquanto na classificação supervisionada, o classificador orienta a sua busca de classes a partir de amostras de treino feitas anteriormente com as classes de interesse da área de estudo.

3.1.1. Classificação Não-Supervisionada

Nos classificadores não-supervisionados é o próprio classificador a identificar as amostras espectrais distintas que poderão existir na imagem num processo iterativo, sendo os mais utilizados o K-MEANS e o ISODATA que também chamados algoritmos de agrupamento. Neste tipo de classificadores o objetivo 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 efetuada a classificação o utilizador terá de inferir sobre a natureza das classes que o algoritmo classificou, isto é, 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 verificar-se 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 respetivas 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.

No caso destas classificações, quanto maior a heterogeneidade das amostras, maior a certeza de que todas as classes possíveis estarão representadas. A principal vantagem do uso destes tipos de classificação é o facto de não ser necessário um conhecimento prévio da área de estudo, enquanto a sua desvantagem é o facto de o utilizador ter pouco controle sobre a separação entre classes.

3.1.1.1. Método ISODATA

O método de classificação ISODATA é, provavelmente, o mais conhecido e é descrito como um meio de interpretação de imagens de deteção remota assistida por computador. O programa de classificação identifica padrões típicos nos níveis de cinza. Esses padrões são classificados efetuando-se visitas de reconhecimento a alguns poucos exemplos escolhidos para determinar a sua interpretação. Em razão da técnica usada nesse processo, os padrões são geralmente referidos como agrupamentos ou nuvens (“clusters”). Neste tipo de classificação, as classes são determinadas pela análise de agrupamentos (“cluster analysis”). Os pixéis nas áreas de treino são submetidos aos algoritmos de agrupamento que determinam a agregação natural dos dados, considerando a sua distribuição num espaço de n dimensões (no caso, bandas espectrais).

3.1.1.2. Método K-MEANS

O método de classificação K-MEANS calcula inicialmente as classes distribuindo em uma classe uniformemente no espaço e então aglomera classe por classe num processo iterativo usando a técnica de distância mínima. Melhor será a classificação quanto melhor for agrupada a nuvem de pixéis. A classificação estará pronta quando o número de iterações definido pelo utilizador for concluído, ou quando for alcançado o critério de número de pixéis que mudam de classe (Change Threshold), como por exemplo se for escolhido 5%, o critério estará alcançado se menos de 5% dos pixéis “migrarem” de uma classe para outra.

3.1.2. Classificação Supervisionada

O princípio da classificação supervisionada é baseado no uso de algoritmos para se determinar os pixéis que representam valores de reflexão características para uma determinada classe. A classificação supervisionada é a mais utilizada na análise quantitativa dos dados de deteção remota.

Numa classificação supervisionada a primeira tarefa a ser realizada é a de selecionar conjuntos de pixéis capazes de descrever espectralmente as classes que se querem classificar, dando-lhes o nome de áreas de treino. Essa seleção poderá ser efetuada 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 respetivas classes. Podemos resumir o processo de classificação supervisionada em três passos principais:

- Seleção de áreas de treino;
- Classificação da imagem;
- Avaliação de resultados.

A escolha das áreas de treino 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 áreas de treino de uma determinada classe e a sua variabilidade espectral, que garantirá a aproximação à natureza da classe. A seleção de áreas de treino é por si só um processo lento, implicando assim uma ação iterativa de escolha e análise da informação estatística das áreas com o objetivo de chegar a um patamar de separabilidade espectral suficiente para garantir resultados satisfatórios na classificação.

De seguida, o operador indica ao classificador as áreas de treino selecionadas, representativas das classes a classificar. Os resultados dependerão naturalmente da qualidade das áreas de teste e da natureza do classificador.

Por último, e depois de terminada a classificação, o operador terá que avaliar a exatidão dos resultados para garantir a qualidade dos mesmos. Para isso, é necessário comparar quantitativamente os resultados obtidos com uma referência ou “verdade de campo” através da elaboração de 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.

3.1.2.1. Método do paralelepípedo

O classificador paralelepípedo atua com base na informação dos histogramas dos componentes espectrais das áreas de treino (Figura 3.1). Este classificador identifica os valores espectrais mínimos e máximos das áreas de treino para cada uma das bandas.

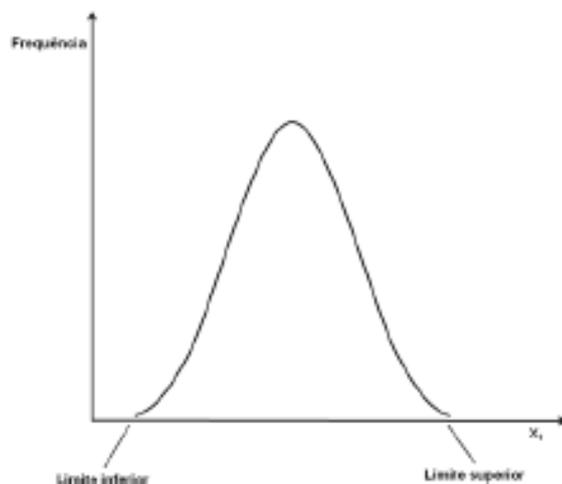


Figura 3.1 – Histograma para os componentes bidimensionais da informação espectral de uma área de treino (adaptado de Crisógono, 2011).

De seguida constrói gráficos de dispersão n-dimensionais, conforme o número de bandas, envolvendo as assinaturas espectrais das áreas de treino em retângulos (Figura 3.2). É com base na representação espacial desses retângulos que o algoritmo faz a classificação. Se determinados pixéis ficam dentro de um retângulo estes são classificados como pertencentes à classe cujo retângulo representa.

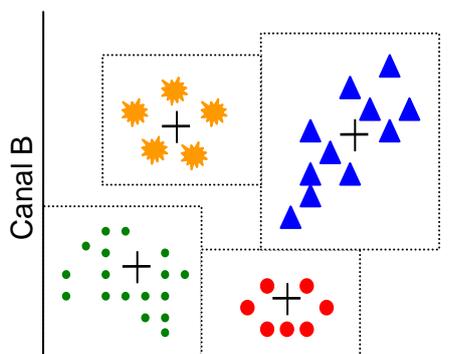


Figura 3.2 – Esquema do método de classificação do paralelepípedo.

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, não tem em conta as probabilidades a priori dos pixéis pertencerem a determinada classe e, por último, em casos onde exista uma sobreposição de retângulos, o algoritmo poderá não conseguir à partida separar os pixéis que pertencem a essas sobreposição (Figura 3.3).

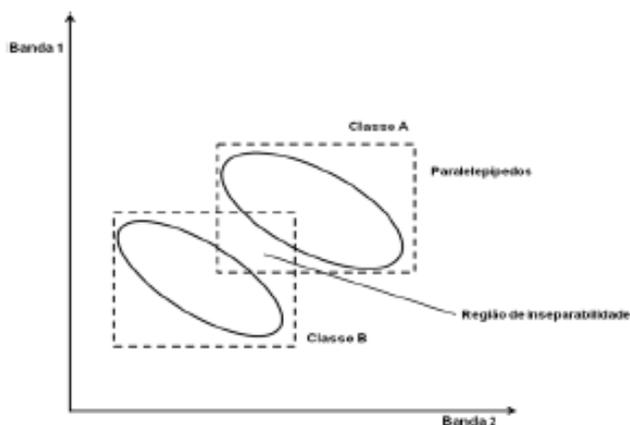


Figura 3.3 – Exemplo de inseparabilidade resultante do classificador paralelepípedo (adaptado de (adaptado de Crisógono, 2011)).

3.1.2.2. Método da distância mínima

O classificador de distância mínima é um algoritmo simples e rápido que não depende do número de pixels selecionado para cada parcela de treino, precisando 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 (Figura 3.4). O algoritmo calcula para cada uma das áreas de treino, uma média que representa o centro geométrico desse conjunto de pixels a que se dá o nome de centróide. Posteriormente calcula a distância euclidiana entre todos os pixels da imagem e os centróides das áreas de treino, classificando o pixel com a classe que corresponder à menor distância calculada.

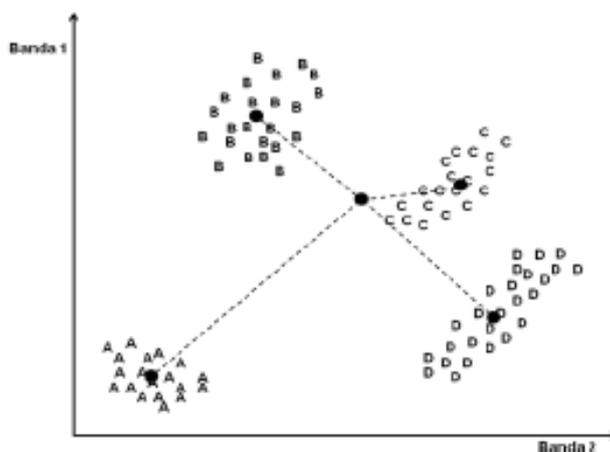


Figura 3.4 – Esquema do método de classificação da distância mínima (adaptado de Crisógono, 2011).

Apesar de muito rápido, o classificador baseia-se apenas na informação espectral das áreas de treino. Dado não ter em conta as covariâncias das áreas de treino, este classificador trata essas amostras, no seu domínio espectral, como simétricas, isto é, não tem em consideração, por exemplo, uma amostra espectralmente alongada (Figura 3.5).

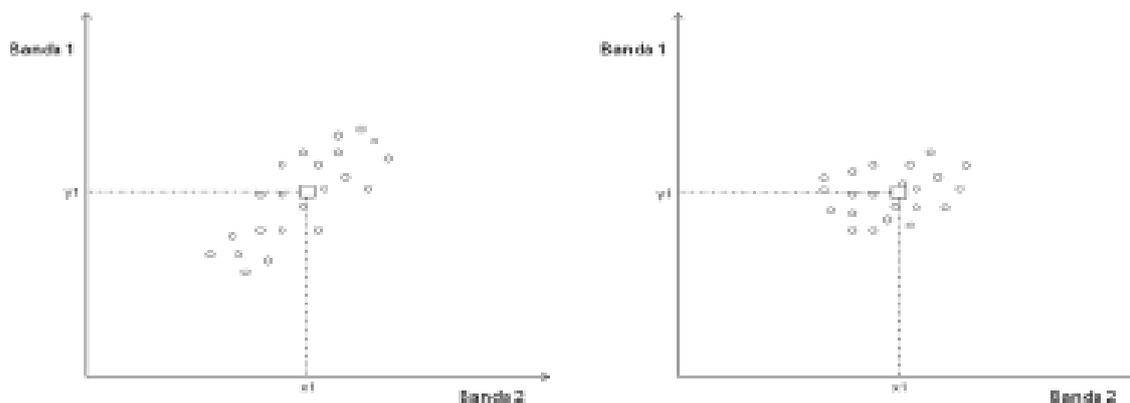


Figura 3.5 – Exemplo de duas amostras espectrais com o mesmo centróide mas com diferentes dispersões (adaptado de Crisógono, 2011).

Neste método, que considera a classe mais provável com base na distância espectral, é realizado o cálculo da média dos pixels em cada banda, para todas as classes e calculada também a distância de um pixel à média de cada banda por classe. Logo, quanto maior a diferença espectral entre o pixel e a classe, maior a distância entre eles, portanto serão mais facilmente separados. Se o pixel for idêntico à média de uma classe, então a distância espectral entre pixel e esta classe é nula (Ribeiro *et al.*, 2009).

O cálculo da distância mínima é efetuado através da seguinte equação:

$$D(x, w_j) = \sqrt{\sum_{i=1}^m (x_i - m_{ij})^2}$$

Onde,

$D(x, w_j)$ – é a diferença espectral;

$m_{i,j}$ – é o valor da média da classe j na banda i .

Uma desvantagem deste tipo de cálculo deve-se à dispersão dos valores de reflectância em torno das médias.

3.1.2.3. Método da 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 áreas de treino num gráfico de dispersão, isto é, que não existe variabilidade nas áreas de treino nas n-dimensões da imagem. A distância de Mahalanobis incorpora na distância euclidiana a dispersão das áreas de treino no espaço n-dimensional da imagem, ou seja., tem em conta a forma da nuvem de pixéis das áreas de treino (Figura 3.6), na forma de matrizes de variância-covariância, conseguindo assim considerar a orientação e dispersão dos dados.

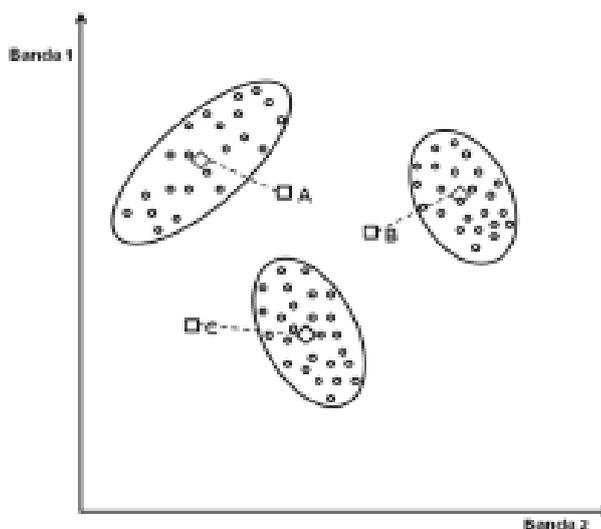


Figura 3.6 – Esquema do método de classificação da distância de Mahalanobis (adaptado de Crisógono, 2011).

3.1.2.4. Método da máxima verossimilhança

O classificador de máxima verossimilhança (Maxver) 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 áreas de treino de cada classe apresentam uma distribuição Gaussiana. Para isso, avalia a média, variâncias e covariâncias das áreas de treino, para assim determinar a distribuição Gaussiana de cada uma delas.

Esta distribuição é traduzida pela função de densidade de probabilidade com base no teorema de Bayes. É com esta função que o algoritmo 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 áreas 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 (Figura 3.7).

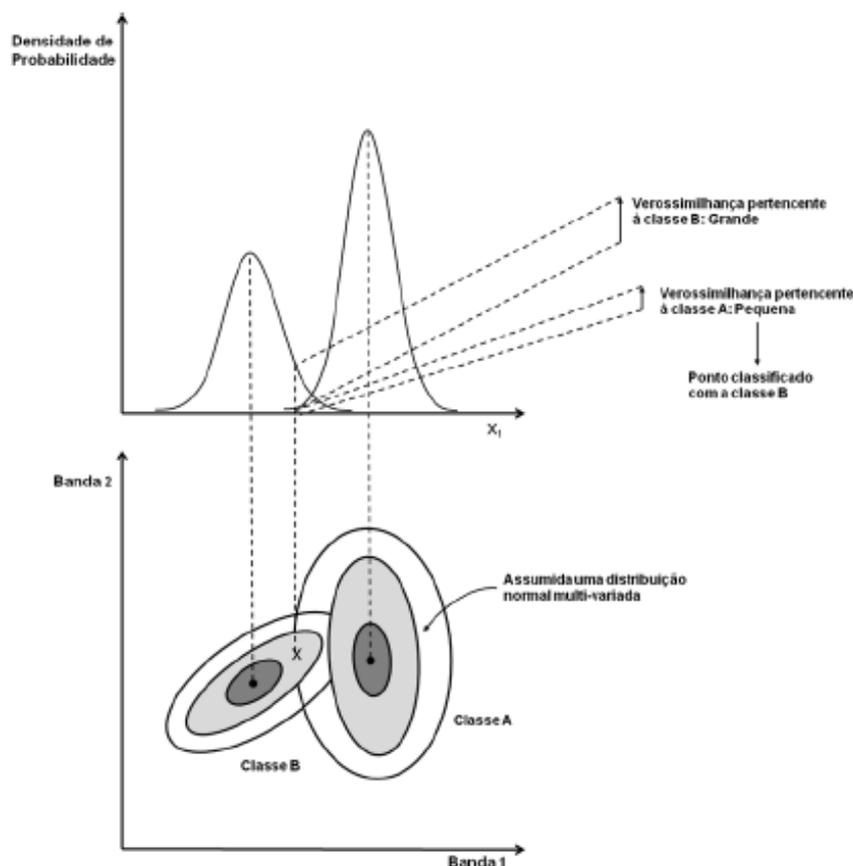


Figura 3.7 – Esquema do método de classificação da máxima verossimilhança (adaptado de Crisógono, 2011).

A eficácia do Maxver depende, principalmente, de uma precisão razoável da estimativa do vetor médio (m) e da matriz de covariância (S) de toda a classe espectral. Isso depende da quantidade de pixéis incluídos nas áreas de treino. Sendo x o vetor correspondente a um pixel nas n classes envolvidas, o vetor médio dos pixéis pertencentes a uma classe é dado por:

$$m = E(x) = \frac{1}{K} \sum_{j=1}^K x_j$$

Onde K é o número de pixéis na classe e $E(x)$ a esperança de x , uma notação estatística para estimar a média de x .

Já a matriz de covariância será dada por:

$$S_x = E\{(x - m)(x - m)^2\} \frac{1}{K - 1} \sum_{j=1}^K (x - m)(x - m)^2$$

Cada área de treino é representada por pixéis com reflexão característica e vale como área de referência dos níveis de cinzento da classe. O resultado do Maxver é melhor quanto maior o número de pixéis numa área de treino para implementá-los na matriz de covariância. Se os tamanhos das áreas de treino para as classes são limitados, recomenda-se um método de classificação mais simples e rápido que não use uma matriz de covariâncias, como por exemplo o método da distância mínima ou do paralelepípedo.

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 pixéis suficientes nas áreas de treino que permitam valores significativos de médias, variâncias e covariâncias. 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.

3.1.2.5. Método *Spectral Angle Mapper*

A natureza geométrica dos pixéis no espaço n-dimensional de uma imagem pode ser descrita de duas maneiras: segundo o seu comprimento vetorial ou segundo o ângulo medido entre um dos eixos do sistema de coordenadas do espaço n-dimensional e o vetor definido pelo ponto de origem do sistema de coordenadas e o pixel.

O Mapeador do ângulo espectral (*“Spectral Angle Mapper”*, SAM) é um método de classificação que usa o ângulo entre as áreas de treino no espaço de n dimensões para determinar os pixéis para uma determinada classe. O algoritmo determina a similaridade espectral entre dois espectros e calcula o ângulo entre eles. Os ângulos são tratados como vetores no espaço n dimensional (Figura 3.8).

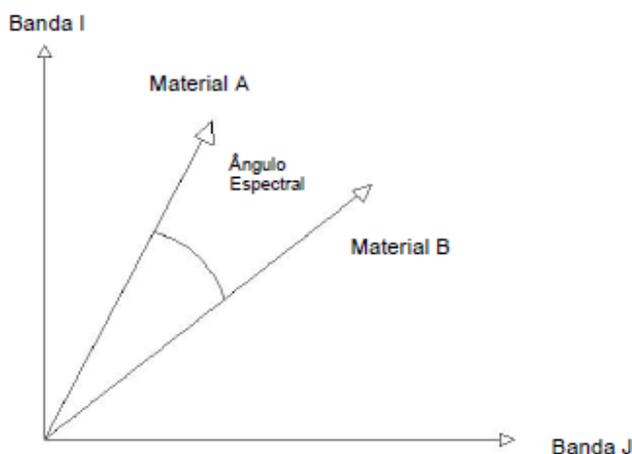


Figura 3.8 – Exemplo do método SAM bidimensional (adaptado de Crisógono, 2011).

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, isto é, o ângulo espectral do pixel a classificar é comparado com os ângulos espectrais que discriminam as áreas de treino (ângulos de fronteira entre áreas de treino) e classificado conforme o seu ângulo seja maior ou menor que esses ângulos espectrais fronteiros (Figura 3.9).

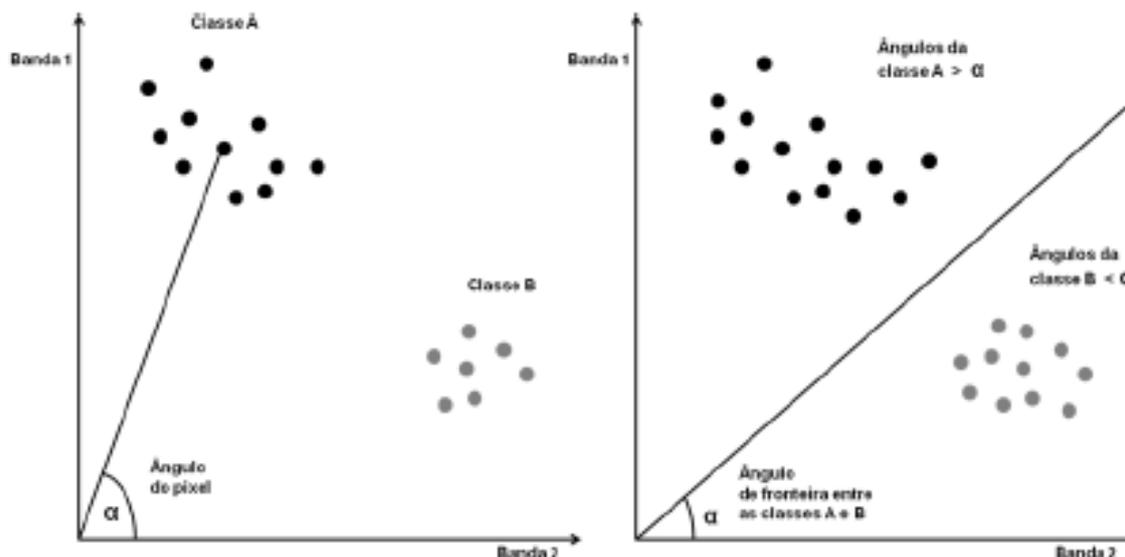


Figura 3.9 – Exemplo de dois elementos com o mesmo ângulo e magnitudes diferentes na imagem mais à esquerda e dois elementos com ângulos diferentes e magnitudes diferentes na imagem mais à direita (adaptado de Crisógono, 2011).

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

Esta técnica possui a grande vantagem de os espectros (“endmembers”) não serem muito sensíveis aos efeitos da iluminação e do albedo. Ângulos menores representam relações mais próximas ao espectro de referência. Pixéis fora do ângulo máximo definido não são classificados.

Este método considera dados reduzidos à reflectância aparente, reflectância original multiplicada por alguns fatores de ganho não conhecidos que dependem da topografia e da sombra. O SAM só usa a direção dos vetores e não o seu módulo, o que significa que todas as iluminações possíveis são tratadas da mesma maneira. A cor de um material é definida pelo seu vetor próprio.

3.1.2.6. Método *Spectral Information Divergence*

O algoritmo do método *Spectral Informations Divergence* (SID) compara a semelhança entre dois pixéis através da medição da probabilidade da discrepância entre as duas assinaturas espectrais correspondentes. A probabilidade espectral discriminatória calcula as probabilidades espectrais de uma base de dados espectral (biblioteca) relativamente a um pixel a ser identificado, de modo a conseguir a identificação do material. A fim de comparar o poder discriminatório de uma medição espectral relativa a outra, é também introduzido um critério para a avaliação de desempenho, que se baseia no poder de discriminação de um pixel em relação a um pixel de referência. Este método caracteriza a variabilidade espectral de forma mais eficaz do que é normalmente usado no SAM.

3.1.2.7. Método de codificação binária

O algoritmo de codificação binária atribui a todos os pixéis 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 (Tabela 3.1). De seguida, classifica a imagem efetuando a operação “OU exclusivo” entre a imagem e as áreas de treino.

Tabela 3.1 – Exemplo do resultado do operador “OU exclusivo”

Operador "OU exclusivo"		
A	B	Resultado
0	0	0
1	0	1
0	1	1
1	1	0

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”, isto é., perde-se muito do pormenor espectral da imagem na codificação binária da imagem.

3.1.3. Árvores de Decisão

Um meio eficiente para representar classificadores a partir de dados é o uso de árvores de decisão. Esta técnica tem como ponto forte a sua eficiência em termos de tempo de processamento e fornecimento de um meio intuitivo de analisar os resultados, por apresentar, como estrutura final do classificador, uma forma de representação simbólica simples e normalmente bastante compreensível, o que facilita a compreensão da análise (Garcia, 2003).

Os fundamentos dos classificadores baseados em árvores de decisão são idênticos, embora sejam muitas as possibilidades existentes para a sua construção. Os algoritmos baseiam-se na sucessiva divisão de uma classe em várias subclasses de menores dimensões, até que as subclasses não possam ser mais divididas, ou seja, esta divisão ocorre até que cada uma destas subclasses não necessitem de mais divisões, gerando assim um nodo folha.

A estrutura de uma árvore de decisão é formada por nodos que representam os atributos, por ramos (ligações) provenientes dos nodos, que recebem os possíveis valores do atributo em questão e de nodos folha, que representam as diferentes classes de um conjunto de dados (Figura 3.10).

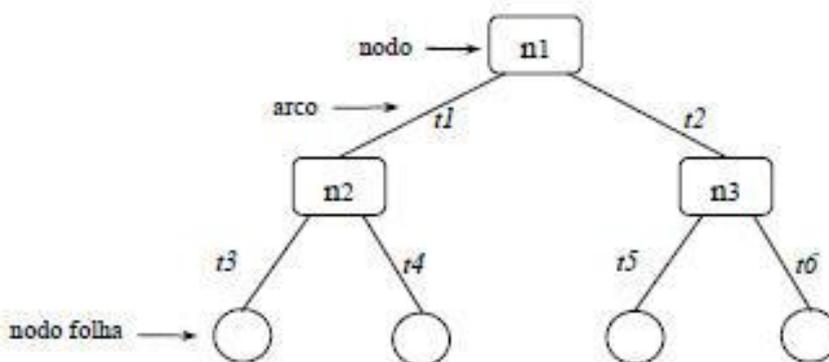


Figura 3.10 – Estrutura de uma árvore de decisão (adaptado de Garcia, 2003).

Dentro da filosofia das árvores de decisão, a classificação consiste em seguir o caminho determinado pelos sucessivos nodos dispostos ao longo da árvore até ser alcançado uma folha, que contém a classe a ser atribuída ao respetivo pixel. Estes caminhos são percorridos através de condições que são impostas aos dados, sendo estas condições os selecionadores dos caminhos a percorrer pelos dados (Figura 3.11).

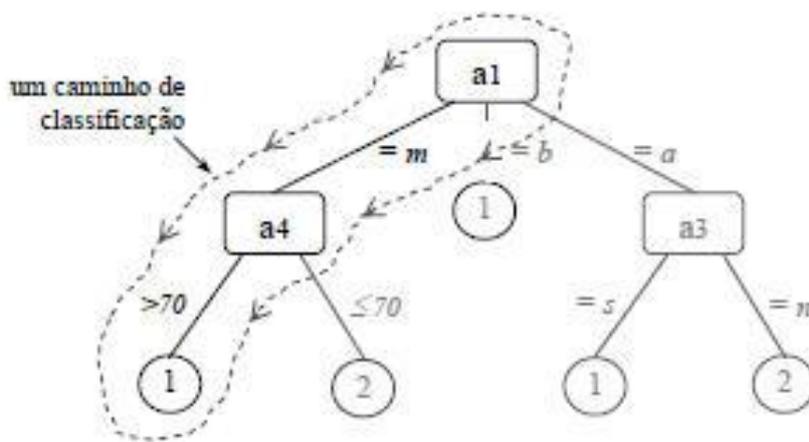


Figura 3.11 – Exemplo de um caminho da classificação de uma árvore de decisão (adaptado de Garcia, 2003).

Deste modo, pode-se verificar que este tipo de classificação, para além da fácil execução e compreensão, produz bons resultados por terem em conta diversos tipos de dados e por ser manipulado pelo utilizador quase na totalidade da classificação, dependendo assim, o resultado final, apenas da qualidade dos dados.

3.2. Comparação e verificação dos resultados das classificações

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. O controlo dos resultados da classificação é um dos passos mais importantes para se chegar a um resultado homogêneo, mas também para controlar a qualidade das diferentes classificações aplicadas. Para efetuar este controlo existe dois métodos de avaliação de exatidão temática, sendo eles, a matriz de confusão e o índice de concordância Kappa.

3.2.1. Matriz de confusão ou de erros (Confusion Matrix ou Error Matrix)

A matriz de confusão (Tabela 3.2) apresenta-se em forma de tabela de dupla entrada e permite confrontar o número de píxeis classificados com o número de píxeis de referência para cada uma das classes. A matriz de confusão é uma matriz quadrada, isto é, tem igual número de colunas e linhas, na sua diagonal principal estão representados o número de píxeis bem classificados, os elementos não-diagonais representam o número de píxeis classificados erradamente, por omissão ou comissão noutras classes (SulSoft, 2010).

A matriz de confusão foi tradicionalmente usada como uma avaliação global dos resultados. Contudo, reduzir esta ferramenta a uma medida global de exatidão será redutor, uma vez que não é garantido que uma exatidão 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 exatidão global, mas também a exatidão de cada uma das classes, comparando-as com as classes de referência.

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

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

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

Tabela 3.2 – Exemplo de uma Matriz de confusão (adaptado de SulSoft, 2010).

		Verdade de campo			Total	Inclusão [%]	Pixeis bem classificados [%]
		A	B	C			
Classes do mapa temático	A	35	2	2	39	10.2	89.8
	B	10	37	3	50	26	74
	C	5	1	41	47	12.8	87.2
Total de pixeis de campo		50	40	46	136		
Omissão [%]		30	7.5	10.9			83.1

Na tabela anterior existe três classes de interesse (A, B e C), em que a matriz de confusão restringe-se às linhas e colunas referentes a essas classes. Os componentes da diagonal principal da matriz de confusão fornecem o número de pixéis corretamente classificados para cada classe correspondente, como por exemplo, para a classe B foram 37 pixéis corretamente classificados no mapa temático. No entanto, para 10 pixéis dessa mesma classe B no mapa temático, analisando a verdade de campo, constata-se que na realidade pertencem à classe A, bem como outros 3 pixéis que na realidade são da classe C.

Portanto, para os 50 pixéis de classe B do mapa temático, 37 (74%) forma bem classificados, enquanto os restantes 13 (26%) foram mal classificados. Este erro de classificação é denominado erro de inclusão ou comissão (commission), pois se está incluindo pixéis em uma classe quando na verdade eles pertencem a outra ou outras.

Analisando agora do ponto de vista da verdade de campo, a classe C, por exemplo, tem 41 pixéis bem classificados, porém há 2 pixéis seus que são classificados com A e outros 3 que são classificados como B. Este tipo de erro é o erro de omissão (omission), pois nos dois casos está-se a omitir pixéis da classe correta atribuindo-os a outra ou outras classes.

Na última coluna da tabela, temos a exatidão específica de cada classe, isto é, a percentagem de pixéis do mapa temático que foram bem classificados. No final desta coluna, encontramos a exatidão global (accuracy) da classificação, em que neste caso, temos no total 136 pixéis, sendo que no mapa temático 113 foram bem classificados, o que perfaz um percentual de 83.1% do total, que foram bem classificados.

3.2.2. Índice de concordância Kappa

A matriz de confusão é por si só uma medida apropriada na avaliação da exatidão de classificações. No entanto, não considera para a avaliação global o peso das exatidões 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, isto é, 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 exatidão global mais rigorosa, pois tem em conta toda a informação existente numa matriz e não só a diagonal principal como a matriz de confusão.

A equação que fornece o valor de kappa é dada por:

$$\hat{k} = \frac{N \sum_{i=1}^{\gamma} x_{ii} - \sum_{i=1}^{\gamma} x_{i+} x_{+i}}{N^2 - \sum_{i=1}^{\gamma} x_{i+} x_{+i}}$$

Onde,

γ – é o número de linhas e de colunas;

N – é o número total de pontos, o somatório de toda a matriz;

Dividindo o numerador e o denominador de por N^2 ,

$$\hat{k} = \frac{\theta_1 - \theta_2}{1 - \theta_2}$$

Onde,

$$\theta_1 = \frac{\sum_{i=1}^{\gamma} x_{ii}}{N}$$

$$\theta_2 = \frac{\sum_{i=1}^{\gamma} x_{i+} x_{+i}}{N^2}$$

O índice Kappa é portanto uma medida que avalia o grau de concordância entre a imagem classificada e o mapa de referência, podendo ter valores entre -1 e 1. Um índice Kappa maior que 0 indica algum grau de concordância entre os valores e 1 indica uma concordância perfeita (Tabela 3.3).

Tabela 3.3 – Medidas de concordância do Índice Kappa (adaptado de Crisógono, 2011).

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

Pegando no exemplo da matriz de confusão da Tabela 3.2, o seu valor de kappa é de 0,747, que é menor do que a exatidão global de 0,831. Observando os valores na Tabela 3.3, o nível de concordância do índice kappa é substancial.

Com o intuito de verificar que kappa realmente pode ser considerado um avaliador mais adequado, analisaremos de igual modo a mesma matriz de confusão da Tabela 3.2 com algumas pequenas modificações (Tabela 3.4).

Tabela 3.4 – Matriz de confusão anterior modificada (adaptado de SulSoft, 2010).

		Verdade de campo			Total	Inclusão [%]	Pixeis bem classificados [%]
		A	B	C			
Classes do mapa temático	A	35	5	5	45	22.2	77.8
	B	10	32	6	48	33.3	66.7
	C	5	3	35	43	18.6	87.4
Total de pixeis de campo		50	40	46	136		
Omissão [%]		30	20	23.9			75.0

Ao diminuir a exatidão das classes B e C, a exatidão global passou para 75%, uma queda de aproximadamente 10,8%. Já o valor de kappa é agora 0,626, ou seja, teve uma diminuição de cerca de 19,3%. Portanto, o índice kappa é sensível não só a perda de acurácia global como um todo, mas também às variações dos erros de omissão e de inclusão, que ficaram maiores nas classes B e C.

Estes dois tipos de avaliação da exatidão 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 efetuadas.

4. Dados e metodologia utilizada

A área de estudo, os dados e a metodologia utilizada na realização deste trabalho serão mencionados neste capítulo, sendo demonstrada a localização exata da zona das imagens, as resoluções dos respetivos satélites e os metadados das aquisições das imagens. Por fim será descrito pormenorizadamente a metodologia utilizada e como foi realizado as diversas fases do trabalho.

4.1. Área de estudo

A área de estudo, localizada dentro do Município de Lisboa (Figura 4.1) entre os meridianos $9^{\circ} 8' W$ e $9^{\circ} 10' W$ e os paralelos $38^{\circ} 45' N$ e $38^{\circ} 47' N$ do sistema de coordenadas WGS84, tem uma forma quadrada com uma área de aproximadamente 289.68 ha (1.702 km x 1.702 km). Foi escolhido este local devido ao facto deste conter as principais características de interesse para a classificação de imagens, sendo elas edifícios com diversos tipos de telhados, áreas com vegetação relevante, terrenos baldios, entre outros.

A área de estudo é dominada maioritariamente por zonas urbanas densas com uma variedade de construções e diferentes tipos de unidades de transporte (rodovias, ferrovias, ciclovias e caminho pedestre). Existe também duas zonas com arborização densa, algumas zonas com vegetação significativa, campos de relva natural e de relva sintética e zonas com solo descoberto. As características da água também estão presentes na área de estudo (dois pequenos lagos), em que a sua área é insignificativa comparada com a área de estudo total. As variações do terreno encontrado na área de estudo variam de 75 a 120 metros de altitude.

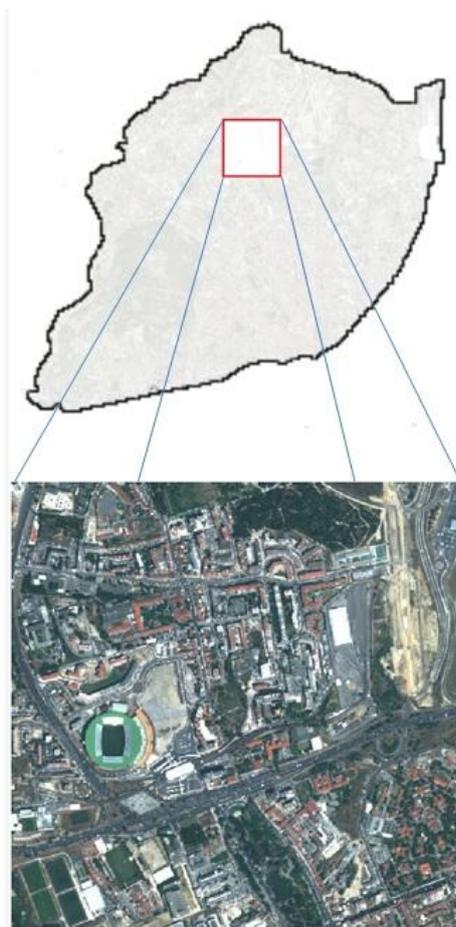


Figura 4.1 – Localização da área de estudo no concelho de Lisboa.

4.2. Dados utilizados

Os dados utilizados neste trabalho são as imagens obtidas pelos satélites QuickBird, Ikonos e WorldView-2 nos anos 2007, 2008 e 2010, respetivamente e o modelo digital de superfície normalizado (nDSM).

4.2.1. Imagens satélite

As imagens de satélite são captadas por sensores eletro-óticos que registam a radiação eletromagnética refletida e emitida pelos objetos que se encontram à superfície da terra através de sinais elétricos proporcionais à radiância da superfície observada. Os sensores que registam imagens de deteção remota podem ser transportados por satélites artificiais da Terra, com formas muito diversas, que se deslocam a diferentes velocidades e cujas órbitas se desenvolvem a altitudes diferentes. As características das plataformas e das suas órbitas condicionam as imagens adquiridas pelos sensores colocados a bordo.

Em termos de resoluções dos satélites, o WorldView-2 é o que possui uma melhor resolução espacial e espectral, como se pode observar na tabela 4.1.

Tabela 4.1 – Resoluções dos satélites QB, IK e WV-2.

Resolução		QuickBird	Ikonos	WorldView-2
Espacial	Pancromática	0.61 metros (nadir) 0.72 metros próximo de 25° (off-nadir)	1 metro	0.46 metros (nadir) 0.52 metros próximo de 20° (off-nadir)
	Multiespectral	2.44 metros (nadir) 2.88 metros próximo de 25° (off-nadir)	4 metros	1.84 metros (nadir) 2.08 metros próximo de 20° (off-nadir)
Espectral	Pancromática	0.45 – 0.9 µm	0.45 – 0.9 µm	0.45 – 0.8 µm
	1ª Banda	0.45 – 0.52 µm (Azul)	0.63 – 0.69 µm (Vermelho)	0.4 – 0.45 µm (Azul costal)
	2ª Banda	0.52 – 0.6 µm (Verde)	0.52 – 0.6 µm (Verde)	0.45 – 0.51 µm (Azul)
	3ª Banda	0.63 – 0.69 µm (Vermelho)	0.45 – 0.52 µm (Azul)	0.51 – 0.58 µm (Verde)
	4ª Banda	0.76 – 0.9 µm (Infravermelho próximo)	0.76 – 0.9 µm (Infravermelho próximo)	0.585 – 0.625 µm (Amarelo)
	5ª Banda	-	-	0.63 – 0.69 µm (Vermelho)
	6ª Banda	-	-	0.705 – 0.745 µm (Vermelho borda)
	7ª Banda	-	-	0.77 – 0.895 µm (Infravermelho próximo)
8ª Banda	-	-	0.86 – 1.04 µm (Infravermelho próximo-2)	
Radiométrica	11 bits (2048 níveis de cinzento)	11 bits (2048 níveis de cinzento)	11 bits (2048 níveis de cinzento)	
Temporal	1 – 3.5 dias (conforme a latitude)	2.9 dias (no modo pancromático) 1.5 dias (no modo multispectral)	1.1 dias (nadir) 3.7 dias próximo de 20° (off-nadir)	
Área Mapeada	16.5 x 16.5 km (nadir) 20.8 x 20.8 km próximo de 25° (off-nadir)	11 x 11 km	16.4 x 16.4 km (nadir)	

4.2.2. Metadados

Todas as imagens de satélite contêm zonas de sombras e distorções, pois estas são adquiridas obliquamente. Deste modo, todos os elementos que tenham uma certa altitude, encontram-se rebatidos e originam sombras, sendo estas maiores quanto maior for os elementos ou quanto mais baixo estiver a elevação do sol ou do satélite. Estes dados são visíveis nos metadados das imagens satélite que são registados no momento das suas aquisições. Assim sendo, o conhecimento destes metadados é importante para que se possa compreender de que forma as características da aquisição da imagem podem condicionar os resultados.

Neste caso em particular, todas as imagens têm algumas sombras sendo a imagem do QB a que se encontra em pior estado. Esta situação pode ser verificada nos metadados, pois na obtenção das imagens, a imagem do QB é que apresenta a elevação do sol mais baixa (Tabela 4.2). As imagens do IK e do WV-2, para além das sombras apresentam umas pequenas distorções nas imagens, sendo elas pouco significantes.

Tabela 4.2 – Metadados das imagens do QB, IK e WV-2.

	Satélite	QuickBird-2	IKONOS-II	WorldView-2
	Data de aquisição	11-03-2007	24-06-2008	29-06-2010
	Hora de aquisição	-	11:27	11:46
	Formato	GeoTIFF	GeoTIFF	GeoTIFF
	Sistema de coordenadas	UTM WGS84	UTM WGS84	UTM WGS84
	Resolution (m)	-	Variável em x e y	2 metros
Sol	Azimute (°)	161.4	129.68	139.7
	Ele vação (°)	46.1	68.48	70.9
Satélite	Azimute (°)	249.3	105.57	28.22
	Ele vação (°)	72.2	68.91	82.09
	Off-nadir (°)	-	21.09	7.1

4.2.3. Modelo Digital de Superfície normalizado

Várias designações coexistem tanto na literatura como nos softwares, pelo que se impõe referir as mais usadas realçando as diferenças nos respetivos significados:

- DTM – Digital Terrain Model, o correspondente na língua inglesa para MDT - Modelo Digital do Terreno;
- DSM - Digital Surface Model, o correspondente na língua inglesa para MDS - Modelo Digital da Superfície;
- DHM – Digital Height Model, termo genérico para DSM e DTM;
- DEM – Digital Elevation Model, igualmente termo genérico para DSM e DTM.

A diferença entre um DTM e um DSM consiste no facto de o primeiro descrever o relevo ao nível do terreno, ignorando o que sobre ele está edificado ou arborizado e o segundo descrever precisamente a superfície terrestre com todas as suas edificações e arvoredo (Figura 4.2).

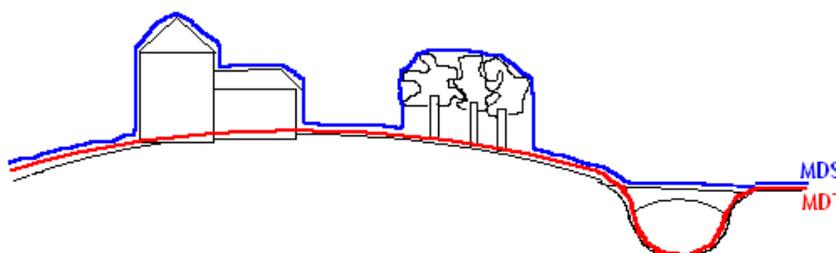


Figura 4.2 – Diferença entre o DTM e o DSM.

O resultado desta diferença é um modelo que contém apenas os objetos acima do terreno, tendo o nome de modelo digital de superfície normalizado (nDSM). A vantagem do uso deste modelo normalizado no estudo em áreas urbanas é que este permite obter diretamente a altura das construções. Neste caso, as zonas mais claras representam as zonas edificadas ou arborizadas, ou seja, as zonas mais elevadas e as zonas mais baixas encontram-se representadas por zonas mais escuras (Figura 4.3).

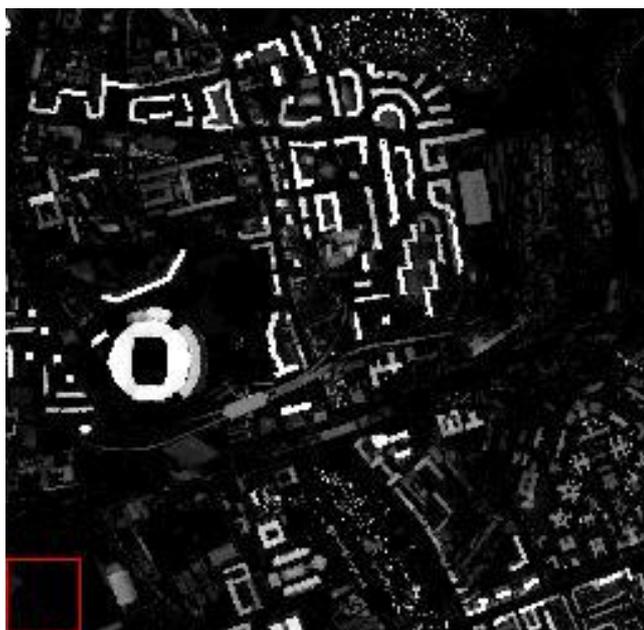


Figura 4.3 – nDSM da área de estudo.

4.2.4. Índices de Vegetação

Para minimizar a variabilidade causada pelos fatores externos, a reflectância espectral da cobertura vegetal tem sido transformada e combinada em vários índices de vegetação. Os que são mais utilizados empregam a informação contida nas reflectâncias de dosséis referentes às regiões do vermelho e do infravermelho próximo, às quais são combinadas sob a forma de razões. Tais índices realçam, em geral, o comportamento espectral da vegetação e correlacionam-se com os parâmetros biofísicos da vegetação, como biomassa, Índice de Área Foliar (IAF) e percentagem de cobertura vegetal. Incluem também elevados graus de correlação com o vigor da vegetação verde, a percentagem de cobertura do solo e a atividade fotossintética.

O Índice de Vegetação por Diferença Normalizada (NDVI) é um dos mais antigos, mais bem conhecido e o mais utilizado índice de vegetação. A combinação na fórmula da diferença normalizada da utilização das regiões mais elevadas de absorção e da reflectância de clorofila torna o índice robusto sobre uma ampla gama de condições. Pode, no entanto, saturar em condições de vegetação densa, quando o IAF torna-se elevado. O valor deste índice varia de -1 a 1, em que o intervalo comum de vegetação verde é de 0.2 a 0.8.

Índice de Vegetação por Diferença Normalizada azul (bNDVI) é igual ao índice anterior, sendo a utilização da banda azul em vez da vermelha a única diferença. Deste modo, este índice não realça tão bem as zonas de vegetação, como o NDVI mas realça muito bem as zonas alcatroadas, mais propriamente as estradas, sendo assim muito utilizado quando pretende-se extrair estas zonas. Como no caso do NDVI, o valor deste índice varia de -1 a 1.

4.3. Metodologia

Nas imagens utilizadas, foi necessário realizar um corte de 2835 x 2835 píxeis na imagem do QB, 1702 x 1702 píxeis na imagem do IK e 3401 x 3401 píxeis na imagem do WV-2, devido ao seu elevado tamanho para o estudo pretendido (Figura 4.4). Esta diferença de píxeis nos cortes deve-se à diferença da resolução espacial das imagens, tendo estas sido descritas anteriormente nas resoluções das imagens satélite. Deste modo, as imagens a serem utilizadas são de menores dimensões, correspondendo todas elas exatamente à mesma zona.



Figura 4.4 – Cortes das imagens do QB, IK e WV-2, respetivamente.

Feito o devido corte nas imagens, estas foram classificadas através dos vários métodos de classificação não-supervisionada e supervisionada disponível no Software ENVI 4.5. Os algoritmos existentes para a classificação não-supervisionada são:

- Isodata
- K-means

Já os algoritmos existentes para a classificação supervisionada são:

- Parallelepiped
- Minimum Distance
- Mahalanobis Distance
- Maximum Likelihood
- Spectral Angle Mapper
- Spectral Information Divergence
- Binary Encoding

Para executar os algoritmos de classificação é necessário definir previamente as classes existentes na área de estudo que serão utilizadas para classificarem as imagens. Neste presente estudo serão utilizados oito tipos de classes predominantes, sendo elas:

- No Data – tudo o que não tenha classificação, mais propriamente as sombras.
- Água – tudo o que seja composto por água, que neste estudo são dois lagos.
- Estradas – todo o tipo de vias de transporte, como por exemplo estradas, linhas ferroviárias, passeios, entre outras.
- Árvores – vegetação mais densa, como por exemplo árvores, arbustos, entre outras.
- Relvado – vegetação mais fina, como por exemplo relva, zonas de cultivo, entre outras.
- Sequeiro – vegetação seca, ou seja, vegetação que apresenta uma cor mais acastanhada.
- Construções – todo o tipo de construções, como por exemplo telhados de telha, terraços e telhados diversos
- Solo Nú – todo o solo que esteja descoberto, como por exemplo zonas em construção, de terra batida, descampados, entre outras.

Na classificação não-supervisionada não será utilizado a classe “água” pelo facto dos algoritmos de classificação nestas imagens não conseguirem distinguir as zonas de água das sombras, atribuindo-as assim à mesma classe, sendo este uma das principais dificuldades neste trabalho. Na execução dos algoritmos deste tipo de classificação foram usadas 21 classes e 3 iterações como parâmetros iniciais, sendo necessário verificar e tratar devidamente todas as classes obtidas. Isto é, após a execução dos algoritmos foi necessário definir as classes predefinidas anteriormente através de modificações e junções das 21 classes obtidas pelo algoritmo.

Feito os devidos tratamento nas imagens classificadas, a validação e comparação dos resultados obtidos foram efetuados através da verificação e análise da matriz de confusão, de cada imagem, para cada uma das classificações. Estas matrizes de confusão resumem as classificações corretas e erros de classificação num formato de tabela de contingência, com as linhas que designam as classes das imagens classificadas e as colunas as classes de referência. Nestas matrizes também são determinadas medidas padrão, como a exatidão global, a precisão, os erros do produtor e do utilizador e o índice kappa, que são obtidas a partir dos resultados de classificação.

Para esta respetiva avaliação das exatidões das imagens classificadas produzidas nos diversos métodos, foi utilizado um método de amostragem estratificada aleatória que servirá como dados de referência. Este método de amostragem deve ser aplicado quando há uma necessidade de assegurar uma dimensão mínima da amostra em cada estrato para derivar estimativas de precisão para todas as classes apresentadas na imagem classificada (Dinis *et al.*, 2010). As unidades de amostras individuais foram definidas como polígonos exibidos na imagem classificada, sendo estes adequados para a avaliação da precisão das imagens geradas através da definição de aglomerados de pixéis, sendo estes grupos homogéneos. (Congalton e Green, 2009).

Além disso, cada unidade de amostra deve ser considerada uma única amostra, isto é, se, por exemplo, um aglomerado de pixéis 3×3 é usada como a unidade de amostragem, então deve ser considerado como uma única amostra e não como nove. Por outro lado, a presença de auto-correlação espacial, na maioria das imagens classificadas, dita que as amostras devem ser adequadamente espaçadas umas das outras (Congalton e Green, 2009). Estendendo o conceito de um conjunto de pixéis para imagens de alta resolução requer um conhecimento sobre a precisão posicional das respetivas imagens. Para imagens de maior resolução espacial, como é o caso destes três satélites, um aglomerado de pixéis 3×3 como unidade de amostragem é adequada, pois quanto maior for o tamanho do pixel maior tem que ser o aglomerado, de modo a ter em conta o erro posicional.

Neste trabalho, um número total de pelo menos 400 polígonos aleatórios foi planeado para servir como amostra, tendo um número mínimo de 50 amostras por cada classe. Neste caso, foram apenas utilizados aproximadamente 17 polígonos para a classe “no data”, 39 polígonos para a classe “estradas”, 47 polígonos para as classes “árvores” e “construções”, 27 polígonos para as classes “relvado”, “sequeiro” e “solo nú” e, por último, 3 polígonos para a classe “água”, tendo considerado as respetivas proporcionalidades das classes. Na classe “água” apenas foram definidas 3 polígonos, para a avaliação da precisão, uma vez que cobre uma pequena parte da área de estudo. Um problema deste método é o facto de existir erros associados na definição das áreas de referência pelo utilizador, adicionando assim uma imprecisão nos resultados obtidos. De forma a minimizar este erro no critério de comparação, foram definidas áreas de treino praticamente nas mesmas zonas das três imagens (Figura 4.5).

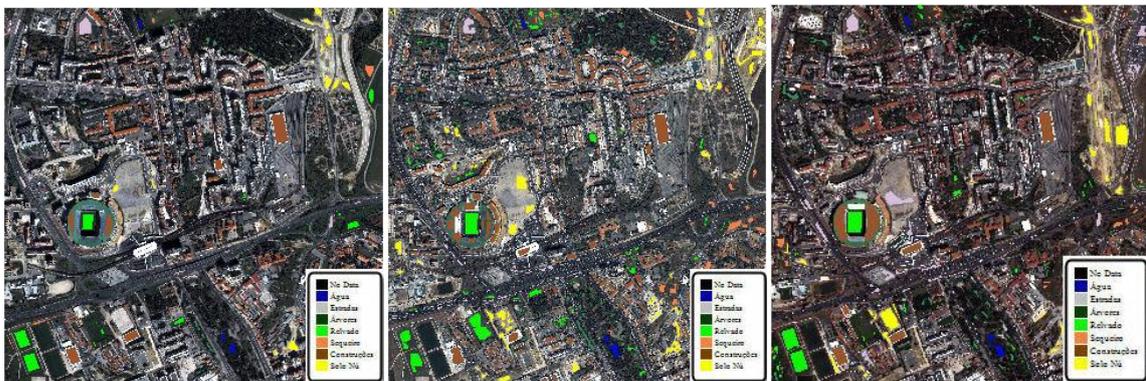


Figura 4.5 – Áreas de referência das imagens do QB, do IK e do WV-2, respetivamente.

Após a execução e análise dos métodos de classificação não-supervisionadas, foram efetuados os respetivos métodos de classificação supervisionadas, utilizando áreas de treino pré-definidas (Figura 4.6). Estas áreas de treino foram definidas com o mesmo esquema das áreas de referência, isto é, o rótulo de referência para cada unidade de amostra foi obtida pela análise visual das imagens. Nestes métodos, a classe “água” já será utilizada, uma vez que neste tipo de classificação são predefinidas áreas de treino que serão usadas como parâmetros iniciais dos algoritmos. De igual modo à escolha das áreas de referência, estas áreas de treino contêm um erro humano associado, mesmo sendo definidas praticamente na mesma zona das imagens.

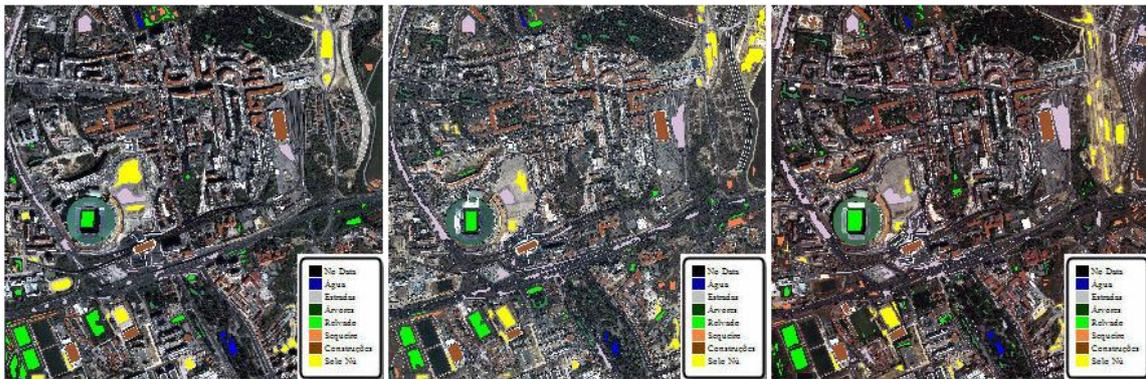


Figura 4.6 – Áreas de treino da imagem do QB, do IK e do WV-2, respetivamente.

Executados os algoritmos de classificação, a validação e comparação dos resultados obtidos foram efetuados da mesma forma que nos métodos de classificação não-supervisionadas, através da verificação e análise das matrizes de confusão. Estas matrizes foram obtidas utilizando as mesmas áreas de referência que foram usadas anteriormente. O facto de se usar as mesmas áreas de treino e áreas de referência, em todos os algoritmos, origina uma homogeneidade na comparação dos resultados.

Para aplicar o último método de classificação de imagens, o das árvores de decisão, foi necessário tratar as imagens de satélite de modo a que haja uma uniformidade em termos de dimensões das imagens, devido a não existir dados nDSM disponíveis nessa zona, ou seja, os dados nDSM têm uma dimensão menor do que as das imagens satélite. Esta uniformização de dimensões das imagens é importante e obrigatória para que os pixels das imagens dos diferentes dados sejam coincidentes, ou seja, quando se analisa um pixel, esse pixel encontra-se na mesma posição em todas as imagens, representando assim o mesmo pixel. Foi também necessário efetuar um ajustamento dos pixels da imagem do nDSM para que esta fosse homogénea às imagens satélite, porque as dimensões dos pixels das imagens satélite são diferentes. Assim sendo, após o devido tratamento das imagens, obteve-se três imagens nDSM com diferentes resoluções espaciais, uma para cada imagem satélite.

Feitos os devidos cortes e ajustamentos nas imagens, foram efetuados e analisados os índices de vegetação NDVI e bNDVI, nas imagens já tratadas, para determinar quais os valores que representam as respetivas classes (Figura 4.7). Deste modo, pode-se verificar os valores que dividem as classes pretendidas, como por exemplo, determinar o valor que divide o que é vegetação do que não é vegetação. O índice de vegetação NDVI foi utilizado para determinar as zonas de vegetação e o índice bNDVI para determinar as zonas de relvado, sequeiro, estradas e solo nú no método das árvores de decisão. De referir que estes valores determinados foram ajustados na própria árvore de decisão através de tentativas erro, de forma a encontrar o valor que apresentasse o melhor resultado.



Figura 4.7 – Imagens dos índices NDVI e bNDVI do WV-2.

Analisados os índices de vegetação foram construídas as árvores de decisão utilizando as imagens satélites, as imagens do índice de vegetação bNDVI que foram obtidas e os dados do nDSM da área de estudo. Não foi necessário utilizar as imagens do índice de vegetação NDVI pois o próprio método realiza o respetivo índice na execução da árvore. Neste tipo de classificação de imagens também não será utilizada a classe “água”, uma vez que não foi possível determinar devidamente estas zonas, tendo sido experimentado a classificação destas zonas através do índice de vegetação bNDVI das imagens. Como as restantes classes são as mesmas para qualquer uma das imagens, a estrutura das árvores de decisão são igual para as três imagens, alterando apenas os valores das condições de classificação (Figura 4.8).

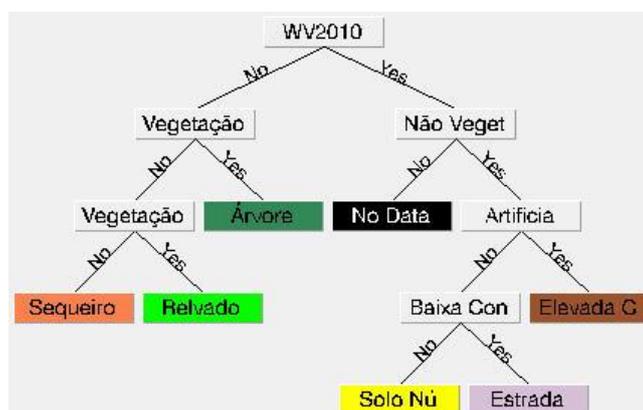


Figura 4.8 – Estrutura da árvore de decisão da imagem do WV-2.

Em termos da estrutura das árvores de decisão, a primeira condição classifica os pixéis do índice de vegetação NDVI acima do valor definido como vegetação e abaixo como não vegetação. Os valores utilizados nesta condição foram 0.35 na imagem do QB, 0.25 na imagem do IK e 0.37 na imagem do WV-2. Dentro da vegetação, a condição classifica os pixéis do nDSM abaixo de 2 metros como vegetação rasteira e acima como “árvores”, sendo esta igual nas três imagens devido aos dados nDSM serem dependentes das zonas da área de estudo, logo iguais em todas as imagens. Já a condição dentro da vegetação rasteira classifica os pixéis do índice de vegetação bNDVI abaixo do valor definido como “sequeiro” e acima como “relvado”. Neste caso, os valores utilizados foram 0.39 na imagem do QB, 0.23 na imagem do IK e 0.35 na imagem do WV-2.

No outro lado da árvore, a condição dentro da não vegetação classifica os pixéis do bNDVI abaixo do valor definido como sombras (“no data”) e acima como artificial. Os valores utilizados nesta condição foram -0.17 na imagem do QB, -0.21 na imagem do IK e -0.33 na imagem do WV-2. Dentro do artificial, a condição classifica os pixéis do nDSM abaixo de 3 metros como baixa construção e acima como elevada construção, estando dentro desta classe tudo o que seja edificado (“construções”). Analogamente à condição dentro da vegetação, esta é igual nas três imagens por serem analisados os dados nDSM. Por último, dentro da baixa construção, a condição classifica os pixéis do bNDVI acima do valor definido como “solo nú” e abaixo como “estradas”. Neste caso, os valores utilizados foram 0.19 na imagem do QB e 0.1 nas imagens do IK e do WV-2.

Construídas e executadas as árvores de decisão para cada imagem, a validação e comparação dos resultados obtidos foram efetuados da mesma forma que nos métodos de classificação não-supervisionadas e supervisionadas. Para obter estas respetivas matrizes de confusão foi necessário definir novas áreas de referência pelo facto de algumas destas que foram definidas anteriormente encontrarem-se fora dos limites da área de estudo, uma vez que as imagens utilizadas neste método são de menores dimensões. Um problema de se usar áreas de referência diferentes das utilizadas nos outros algoritmos de classificação é a não homogeneidade na comparação dos resultados, uma vez que estas ao serem diferentes proporcionaram resultados diferentes. De igual modo às definições das áreas de treino nas diferentes imagens, estas foram definidas praticamente nas mesmas zonas do que as áreas de referência que já tinham sido definidas, minimizando assim o erro de comparação dos resultados.

No fim da aplicação de todos estes métodos de classificação, serão discutidos e analisados todos os resultados obtidos, permitindo assim obter as respetivas conclusões do trabalho.

5. Resultados e discussão

Neste capítulo serão apresentados os resultados obtidos em todos os métodos de classificação de imagem utilizados, bem como as suas respectivas análises e discussões.

5.1. Resultados obtidos

A apresentação dos resultados será efetuada através da exibição de um quadro de síntese, para cada método de classificação, com as exatidões globais, os índices kappa e o respetivo nível de concordância que se obteve nas três imagens. Também serão exibidas as melhores imagens obtidas em cada um dos métodos e as matrizes de confusão obtidas que contenham um índice kappa acima dos 80%, ou seja, um nível de concordância quase perfeito ou perfeito. Estas matrizes serão representadas em percentagens para que as análises e conclusões sejam mais intuitivas, tendo assim uma melhor perceção dos erros obtidos. Assim sendo, será focado apenas a comparação de todos os resultados e a exibição dos melhores resultados obtidos, não tendo em muita consideração os resultados que tiveram maus resultados.

5.1.1. Classificação não-supervisionada

Neste tipo de classificação, como mencionado anteriormente, foram utilizadas 21 classes e 3 iterações como parâmetros de entrada em todos os algoritmos, de modo a que os resultados sejam obtidos de forma igual, não originando assim possíveis diferenças que se poderia obter nos resultados finais. Assim sendo, as diferenças dos resultados finais serão apenas provocadas pelas características das imagens e pelas pequenas diferenças das áreas de referência, permitindo assim analisar e comparar os resultados obtidos quase de forma homogénea.

5.1.1.1. Método ISODATA

Neste método de classificação, após o devido tratamento das imagens obtidas no algoritmo, os resultados não foram muito bons, estando estes na ordem dos 60% de exatidão global. As respetivas exatidões globais, índices Kappa e níveis de concordância obtidos nas matrizes de confusão das três imagens foram (Tabela 5.1):

Tabela 5.1 – Tabela das exatidões globais e índices Kappa obtidos no método ISODATA das três imagens.

	Exatidão Global [%]	Índice Kappa	Nível de Concordância
QuickBird	64.25	0.5717	Moderado
Ikonos	50.04	0.3924	Razoável
WorldView-2	65.39	0.5827	Moderado

As exatidões globais obtidas neste método de classificação foram 64% para a imagem do QB, 50% para a imagem do IK e 65% para a imagem do WV-2, correspondendo estes resultados a um nível de concordância moderado nas imagens do QB e WV-2 e razoável na imagem do IK. Deste modo, pode-se concluir que, em termos espectrais, a imagem do WV-2 é a que apresenta melhores resultados, comparando com as outras duas imagens, apesar da diferença para a imagem do QB ser relativamente pequena, cerca de 1%, enquanto a imagem do IK é a que apresenta o pior resultado neste método.

Neste caso, como explicado anteriormente, não será exibido as matrizes de confusão por os resultados obtidos não serem muito, isto é, não correspondem a uma boa classificação das imagens. Analisando as matrizes de confusão obtidas neste método, pode-se verificar que existem vários erros de comissão, pixéis que foram incluídos porque na realidade não pertencem à classe que foram classificados e erros de omissão, pixéis que foram omitidos porque na realidade pertencem a uma classe mas foram classificados noutra. Mais especificamente, os maiores erros de comissão obtidos, em percentagem, foram na classe “árvores”, da imagem do QB, com 54%, na classe “estradas”, da imagem do IK, com 68% e na classe “sequeiro”, da imagem do WV-2, com 95%. Já os maiores erros de omissão obtidos, também em percentagem, foram na classe “solo nú”, da imagem do QB, com 52% e na classe “sequeiro”, das imagens do IK e WV-2, com 77% e 87% respetivamente.

Em termos globais, as classes que contêm maior percentagem de pixéis mal classificados são a classe “árvores”, com 46%, na imagem do QB, a classe “estradas”, com 32%, na imagem do IK e a classe “sequeiro”, com 5%, na imagem do WV-2. Estes resultados devem-se ao facto de muitos pixéis da classe “árvores” terem sido classificados como “sequeiro” na imagem do QB, muitos pixéis da classe “estradas” terem sido classificados como “construções” na imagem do IK e muitos pixéis da classe “sequeiro” terem sido classificados como “árvores” na imagem do WV-2.

A imagem final do WV-2 obtida neste método de classificação foi (Figura 5.1):

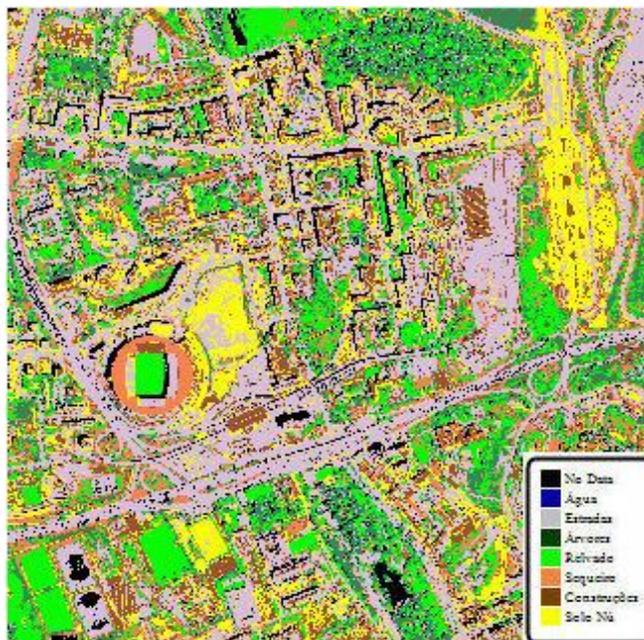


Figura 5.1 – Imagem do WV-2 classificada pelo método ISODATA.

Em termos visuais, a imagem do WV-2 classificada por este método até apresenta uma boa solução, pois contém uma boa parte dos elementos da imagem bem representados. De realçar que como não foi considerada a classe “água”, esta encontra-se classificada como “no data” na imagem. Outro facto visível na imagem é a classificação do estádio de futebol como “sequeiro”, pois este tem uma cor esverdeada confundindo assim o algoritmo de classificação.

5.1.1.2. Método K-MEANS

Atuando do mesmo modo que no método de classificação anterior, neste método os resultados obtidos também não foram muito bons, continuando a estar na ordem dos 60% de exatidão global, podendo assim concluir desde já que estes dois métodos são muito similares. Para este caso, as respetivas exatidões globais, índices Kappa e níveis de concordância obtidos nas matrizes de confusão das três imagens foram (Tabela 5.2):

Tabela 5.2 – Tabela das exatidões globais e índices Kappa obtidos no método K-MEANS das três imagens.

	Exatidão Global [%]	Índice Kappa	Nível de Concordância
QuickBird	62.67	0.5537	Moderado
Ikonos	51.14	0.4155	Moderado
WorldView-2	65.54	0.5850	Moderado

As exatidões globais obtidas neste método de classificação foram 63% para a imagem do QB, 51% para a imagem do IK e 66% para a imagem do WV-2, correspondendo estes resultados a um nível de concordância moderado nas três imagens. Deste modo pode-se concluir que, em termos espectrais, a imagem do WV-2 continua a apresentar melhores resultados e a imagem do IK o pior resultado. Neste caso, a diferença da imagem do WV-2 para a imagem do QB aumentou ligeiramente devido ao resultado da imagem do WV-2 ter melhorado e o resultado da imagem do QB ter piorado, em cerca de 1% em ambos os casos, enquanto o resultado da imagem do IK também melhorou cerca 1% neste método.

Analogamente ao método de classificação anterior, não será exibida nenhuma matriz de confusão porque a classificação das imagens continua a não ser muito boa. Analisando as respetivas matrizes de confusão obtidas, pode-se verificar que continua a existir vários erros de comissão e de omissão. Mais especificamente, os maiores erros de comissão obtidos, em percentagem, foram na classe “solo nú”, da imagem do QB, com 51%, na classe “estradas”, da imagem do IK, com 71% e na classe “sequeiro”, da imagem do WV-2, com 92%. Já os maiores erros de omissão obtidos, também em percentagem, foram na classe “árvores”, da imagem do QB, com 60%, na classe “construções”, da imagem do IK, com 71% e na classe “sequeiro”, da imagem do WV-2, com 79%. De realçar que na imagem do QB, as classes que apresentaram maiores erros de comissão e omissão foram exatamente iguais às do método anterior, só que invertidos, e a classe “relvado” tem 0% de pixéis omitidos, tendo estes sido todos classificados em todos os pixéis desta classe que existem na realidade. Na imagem do IK, a classe que apresentou maior erro de comissão foi a mesma do que no método anterior, o que não aconteceu na classe que apresentou maior erro de omissão. Por último, na imagem do WV-2, a classe que apresentou o maior erro de comissão e omissão foi exatamente a mesma do que no método anterior, podendo assim concluir que ambos os métodos de classificação tiveram dificuldades em classificar a classe “sequeiro”, devendo-se este facto às características da imagem.

Em termos globais, as classes que contêm maior percentagem de pixéis mal classificados são a classe “solo nú”, com 49%, na imagem do QB, a classe “estradas”, com 30%, na imagem do IK e a classe “sequeiro”, com 8%, na imagem do WV-2. Estes resultados devem-se ao facto de muitos pixéis da classe “solo nú” terem sido classificados como “construções” na imagem do QB e muitos pixéis das classes “estradas” e “sequeiro” terem sido classificados como “árvores”, na imagem do IK e do WV-2, respetivamente.

A imagem final do WV-2 obtida neste método de classificação foi (Figura 5.2):

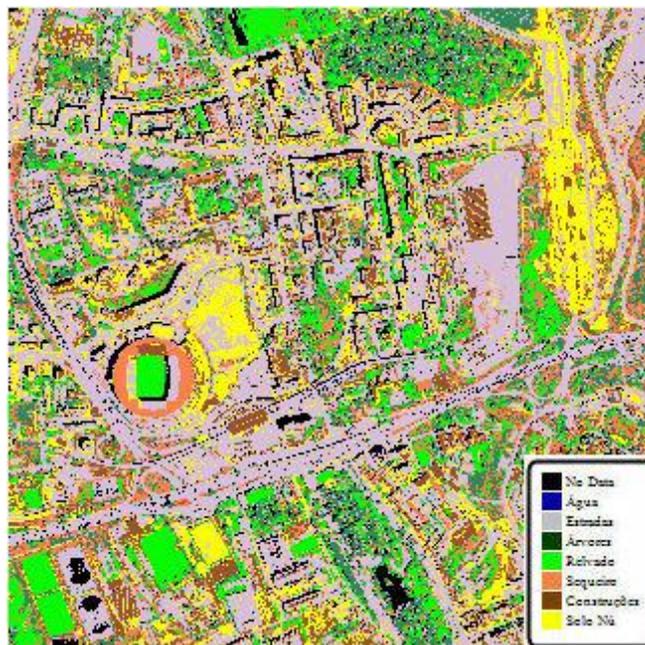


Figura 5.2 – Imagem do WV-2 classificada pelo método K-MEANS.

Como os resultados dos métodos ISODATA e K-MEANS foram semelhantes, é lógico que as imagens do WV-2 classificadas também sejam semelhantes. Este facto é visível na imagem anterior, pois esta também apresenta uma boa solução, em termos visuais, como na imagem obtida no método ISODATA. Nesta imagem continua a ser visível a classificação de zonas de água como “no data”, por a classe “água” não ter sido considerada e a classificação do estádio de futebol como “sequeiro”, devido às suas características espectrais.

5.1.2. Classificação supervisionada

Neste tipo de classificação, como mencionado na metodologia, foram definidas áreas de treino das oito classes, praticamente nas mesmas zonas das três imagens, sendo estas utilizadas como parâmetros de entrada em todos os algoritmos deste tipo de classificação. Deste modo, os resultados são obtidos quase de forma homogênea, não originando assim muitas diferenças nos resultados finais. De igual modo aos métodos de classificação não-supervisionadas, as diferenças dos resultados finais serão apenas provocadas pelas características das imagens e pelas pequenas diferenças das áreas de treino e das áreas de referência.

5.1.2.1. Método do paralelepípedo

Neste método de classificação, após a definição das áreas de treino para a três imagens, os resultados obtidos foram piores do que nos métodos de classificação não-supervisionada, variando estes de 25% a 61% de exatidões globais. As respetivas exatidões globais, índices Kappa e níveis de concordância obtidos nas matrizes de confusão das três imagens foram (Tabela 5.3):

Tabela 5.3 – Tabela das exatidões globais e índices Kappa obtidos no método do paralelepípedo das três imagens.

	Exatidão Global [%]	Índice Kappa	Nível de Concordância
QuickBird	61	0.5155	Moderado
Ikonos	24.95	0.1014	Baixo
WorldView-2	40.86	0.2521	Razoável

As exatidões globais obtidas neste método de classificação foram 61% para a imagem do QB, 25% para a imagem do IK e 41% para a imagem do WV-2, correspondendo estes resultados a um nível de concordância moderado na imagem do QB, baixo na imagem do IK e razoável na imagem do WV-2. Deste modo, pode-se concluir que, em termos espectrais, a imagem do QB é a que apresenta melhores resultados, comparando com as outras duas imagens, sendo a diferença para a imagem do WV-2 muito significativa, cerca de 20%. A imagem do IK apresenta um resultado muito mau, sendo a que apresenta o pior resultado.

Como nos métodos de classificação não-supervisionada, não será exibida nenhuma matriz de confusão porque a classificação das imagens foram muito más. Analisando as respetivas matrizes de confusão obtidas, pode-se verificar que, como é normal devido aos fracos resultados, existem vários erros de comissão e omissão. Mais especificamente, os maiores erros de comissão obtidos, em percentagem, foi na classe “árvores”, das imagens do QB, do IK e do WV-2, com 95%, 90% e 85%, respetivamente. Já os maiores erros de omissão obtidos, também em percentagem, foram na classe “solo nú”, das imagens do QB, do IK e do WV-2 e na classe “água”, da imagem do IK, com 100% em todas. Desde modo pode-se concluir que, em todas as imagens, a classe “solo nú” foi omitida, pois nenhuns destes pixéis foram classificados nos pixéis correspondentes à mesma classe que existe na realidade, o que também aconteceu na classe “água” da imagem do IK. De realçar que a classe que apresenta maior erro de comissão é a mesma em todas as imagens e que, em todas as imagens, existe pelo menos uma classe que tem 0% de pixéis incluídos, isto é, todos os pixéis que correspondem a essa classe na realidade pertencem à classe que foram classificados, sendo elas a classe “solo nú” nas três imagens e a classe “água” nas imagens do IK e do WV-2. Por estes motivos, é compreensível a fraca qualidade dos resultados, pois existem diversos erros nas classificações das classes.

Em termos globais, o facto de o algoritmo ter eliminado algumas áreas de treino pré-definidas, como é o caso da classe “água” na imagem do IK e a classe “solo nú” nas três imagens, é facilmente visível nas matrizes de confusão obtidas porque estas apresentam uma percentagem de 0% de pixéis bem classificados nestas classes. Excluindo estas respetivas classes, que foram eliminadas pelo algoritmo, a classe que contém maior percentagem de pixéis mal classificados é a classe “árvores”, com 5%, 10% e 15% respetivamente nas três imagens, podendo assim concluir que este método não classifica muito bem as zonas arborizadas. Estes resultados devem-se ao facto de muitos pixéis da classe “árvores” terem sido classificados como “estradas” em todas as imagens. Assim sendo, pode-se concluir que este método de classificação confunde a classe “árvores” como sendo “estradas”, devendo-se este facto ao comportamento do algoritmo nestes dados utilizados. De realçar que na imagem do WV-2, a classe “água” teve 100% de pixéis bem classificados.

A imagem final do QB obtida neste método de classificação foi (Figura 5.3):

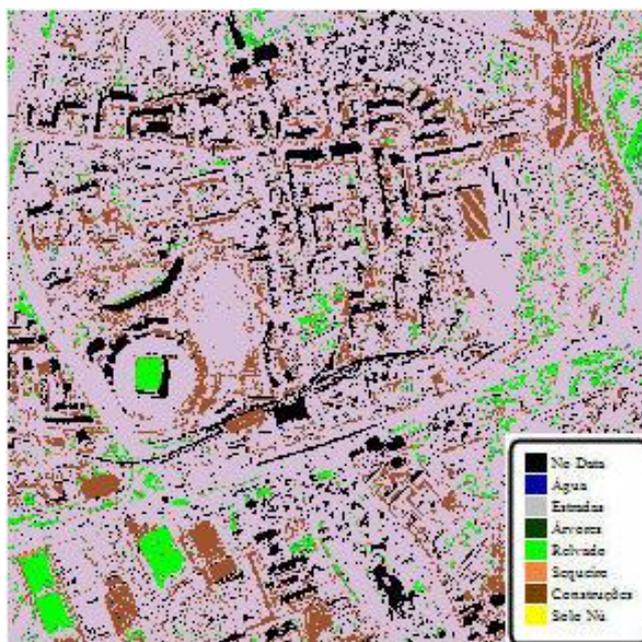


Figura 5.3 – Imagem do QB classificada pelo método do paralelepípedo.

Contrariamente às imagens obtidas nos métodos de classificação não-supervisionadas, esta não apresenta uma boa solução, em termos visuais, pois não representa devidamente os elementos da imagem, sendo espectável devido aos fracos resultados obtidos na matriz de confusão. De realçar que, como foi observado anteriormente nos resultados das matrizes de confusão, a classe “solo nú” não se encontra representada na imagem. Outro facto visível na imagem é a predominância da classe “estradas”, verificando-se assim que existem vários elementos mal classificados.

5.1.2.2. Método da distância mínima

Atuando do mesmo modo que no método de classificação anterior, neste método os resultados obtidos também foram maus, apesar de terem melhorado, variando estes de 51% a 70% de exatidão global. Para este caso, as respetivas exatidões globais, índices Kappa e níveis de concordância obtidos nas matrizes de confusão das três imagens foram (Tabela 5.4):

Tabela 5.4 – Tabela das exatidões globais e índices Kappa obtidos no método da distância mínima das três imagens.

	Exatidão Global [%]	Índice Kappa	Nível de Concordância
QuickBird	69.94	0.6386	Substancial
Ikonos	51.23	0.4220	Moderado
WorldView-2	53.39	0.4499	Moderado

As exatidões globais obtidas neste método de classificação foram 70% para a imagem do QB, 51% para a imagem do IK e 53% para a imagem do WV-2, correspondendo estes resultados a um nível de concordância substancial na imagem do QB e moderado nas imagens do IK e do WV-2. Neste método, os resultados foram todos melhores do que no método anterior, continuando a imagem do QB a apresentar os melhores resultados, comparando com as outras duas imagens. A diferença desta para a imagem do WV-2 continua a ser significativa, cerca de 17%, apesar da diminuição de 3% dessa diferença. Como tem vindo a acontecer, a imagem do IK é a que apresenta o pior resultado, sendo de realçar o seu melhoramento de 26%, comparando-o com o método anterior.

Analogamente a todos os métodos de classificação executados anteriormente, não será exibida nenhuma matriz de confusão porque os valores dos resultados da classificação das imagens continuam a não corresponder com os valores pretendidos. Analisando as respetivas matrizes de confusão obtidas, os maiores erros de comissão obtidos, em percentagem, foram na classe “água”, da imagem do QB, com 71%, na classe “no data”, da imagem do IK, com 76% e na classe “sequeiro”, da imagem do WV-2, com 82%. Já os maiores erros de omissão obtidos, também em percentagem, foram na classe “construções”, das imagens do QB, do IK e do WV.2, com 58%, 73% e 84%, respetivamente. De realçar que a classe “construções” foi a classe que apresentou maior percentagem de pixéis omitidos em todas as imagens. Neste caso, não houve um relacionamento dos resultados obtidos neste método com os obtidos no método anterior pelo facto do comportamento destes dois algoritmos serem diferentes, procedendo assim de maneira diferente nos mesmos dados.

Em termos globais, contrariamente ao algoritmo do método anterior, não foi eliminado nenhuma área de treino pré-definida, mas continua a haver muitos pixéis mal classificados. As classes que tiveram maior percentagem de pixéis mal classificados foram a classe “água”, com 29%, na imagem do QB, a classe “no data”, com 24%, na imagem do IK e a classe “sequeiro”, com 18%, na imagem do WV-2. Neste caso, não houve uma relação entre as classes que maior percentagem de pixéis mal classificados nas imagens, não havendo assim uma influência direta do algoritmo, como acontecia com a classe “árvores” no método anterior. Estes resultados devem-se ao facto de muitos pixéis da classe “água” terem sido classificados como “no data” nas imagens do QB, muitos pixéis da classe “no data” terem sido classificados como “água” na imagem do IK e muitos pixéis da classe “sequeiro” terem sido classificados como “árvores” na imagem do WV-2. De realçar que as classes que o algoritmo confundiu nas imagens do QB e do IK são as mesmas só que inversamente.

A imagem final do QB obtida neste método de classificação foi (Figura 5.4):

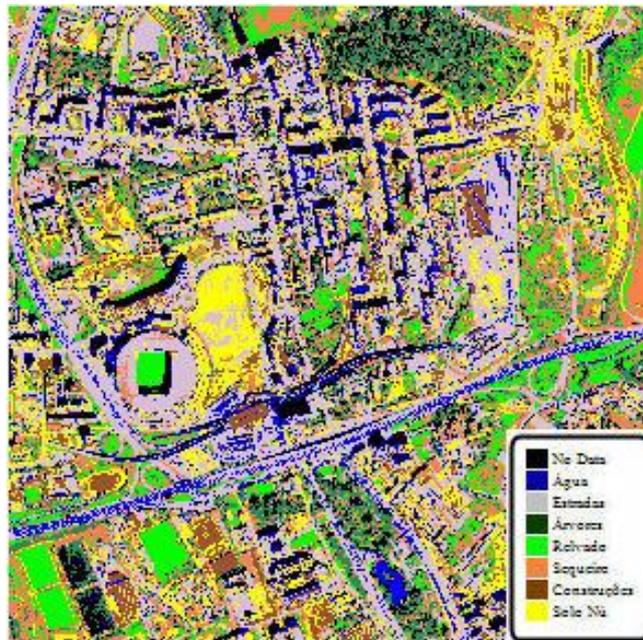


Figura 5.4 – Imagem do QB classificada pelo método da distância mínima.

Comparando esta imagem com a obtida no método de classificação anterior, verifica-se um melhoramento em termos visuais, pois esta contém a representação de todas as classes nos elementos da imagem. Apesar de esta ter a representação de todas as classes, a imagem não se encontra devidamente correta pelo facto destas classes estarem a representar os elementos errados. Um pormenor desta má representação na imagem é a maioria das “estradas” estarem classificadas como “água”, sendo este facto visível na imagem e na matriz de confusão obtida.

5.1.2.3. Método da distância de Mahalanobis

Neste método de classificação, os resultados obtidos já começam a ser bastante melhores, estando estes na ordem dos 70% de exatidão global. Para este caso, as respetivas exatidões globais, índices Kappa e níveis de concordância obtidos nas matrizes de confusão das três imagens foram (Tabela 5.5):

Tabela 5.5 – Tabela das exatidões globais e índices Kappa obtidos no método da distância de Mahalanobis das três imagens.

	Exatidão Global [%]	Índice Kappa	Nível de Concordância
QuickBird	77.40	0.7303	Substancial
Ikonos	61.31	0.5442	Moderado
WorldView-2	72.94	0.6757	Substancial

As exatidões globais obtidas neste método de classificação foram 77% para a imagem do QB, 61% para a imagem do IK e 73% para a imagem do WV-2, correspondendo estes resultados a um nível de concordância substancial na imagem do QB e do WV-2 e moderado na imagem do IK. Os resultados obtidos neste método foram todos melhores do que nos métodos anteriores, sendo de realçar a significativa diminuição da diferença entre as imagens do QB e do WV-2, mais especificamente, de 17% para 4%. Apesar da melhoria de 20% do resultado obtido da imagem do WV-2, a imagem do QB continua a apresentar o melhor resultado, comparando com as outras duas imagens. Relativamente à imagem do IK, esta continua a apresentar o pior resultado, sendo de realçar a sua melhoria de 10% comparado com o resultado obtido no método anterior.

Neste caso, não será exibida nenhuma matriz de confusão por muito pouco, pois a imagem classificada do QB encontrasse muito perto do nível de concordância quase perfeito. Analisando as respetivas matrizes de confusão obtidas, pode-se verificar que os erros de comissão e omissão são mais pequenos, refletindo-se nos resultados das classificações. Os maiores erros de comissão obtidos, em percentagem, foram na classe “água”, da imagem do QB e do IK, com 86% e 81%, respetivamente e na classe “no data”, da imagem do WV-2, com 64%. Já os maiores erros de omissão obtidos, também em percentagem, foram na classe “construções”, das imagens do QB, do IK e do WV-2, com 49%, 63% e 53%, respetivamente. Como se tinha sucedido no método de classificação anterior, a classe “construções” foi a classe que apresentou maior percentagem de pixéis omitidos em todas as imagens, podendo assim concluir que o comportamento do algoritmo destes dois métodos é muito similar, podendo de forma ser confirmado através dos resultados obtidos.

Em termos globais, as classes que tiveram maior percentagem de pixéis mal classificados foram a classe “água”, com 14% e 19%, na imagem do QB do IK, respetivamente e a classe “no data”, com 36%, na imagem do WV-2. Na imagem do QB, a classe “água” continua a ser a classe com maior percentagem de pixéis mal classificados, comparado com o método anterior, o que não aconteceu nas outras imagens. Estes resultados devem-se ao facto de muitos pixéis da classe “água” terem sido classificados como “no data” nas imagens do QB e do IK e muitos pixéis da classe “no data” terem sido classificados como “estradas” na imagem do WV-2. Neste caso, como no método anterior, não houve uma relação das classes que apresentaram maior percentagem de pixéis mal classificados, não havendo assim uma influência direta do algoritmo nos resultados obtidos.

A imagem final do QB obtida neste método de classificação foi (Figura 5.5):

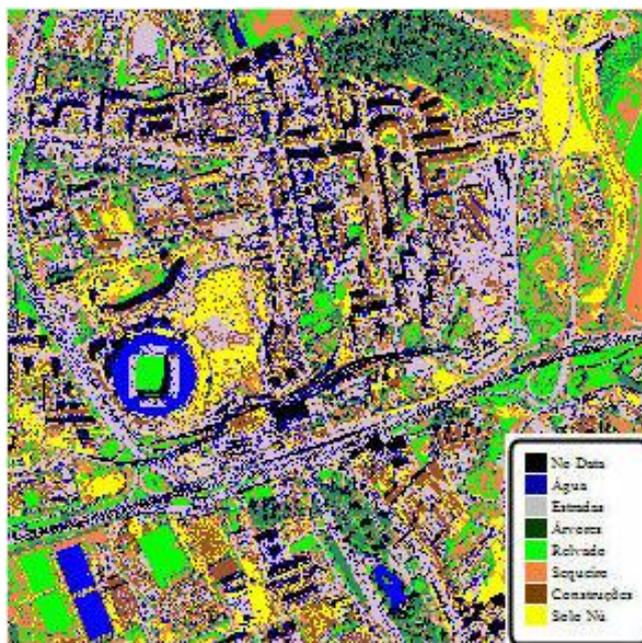


Figura 5.5 – Imagem do QB classificada pelo método da distância de Mahalanobis.

Comparando esta imagem com as obtidas nos métodos de classificação anteriores, continua-se a verificar um melhoramento em termos visuais, pois esta contém a representação dos elementos da imagem um pouco melhores. Do mesmo modo que o método anterior, a imagem continua a não representar devidamente alguns elementos, voltando a ser visível o pormenor da maioria das “estradas” estarem classificadas como “água”, bem como o estádio de futebol. Este facto também pode ser visível na matriz de confusão, pois esta foi a classe que teve maior percentagem de pixéis mal classificados na imagem.

5.1.2.4. Método da máxima verossimilhança

Para este método de classificação, os resultados obtidos foram muito bons, estando estes na ordem dos 90% de exatidão global. Até ao momento, estes foram os melhores valores obtidos na classificação destas três imagens. Enquanto às suas respetivas exatidões globais, índices Kappa e níveis de concordância obtidos nas matrizes de confusão foram (Tabela 5.6):

Tabela 5.6 – Tabela das exatidões globais e índices Kappa obtidos no método da máxima verossimilhança das três imagens.

	Exatidão Global [%]	Índice Kappa	Nível de Concordância
QuickBird	95.12	0.9383	Quase Perfeito
Ikonos	83.68	0.7954	Substancial
WorldView-2	95.66	0.9453	Quase Perfeito

As exatidões globais obtidas neste método de classificação foram 95% para a imagem do QB, 84% para a imagem do IK e 96% para a imagem do WV-2, correspondendo estes resultados a um nível de concordância quase perfeito nas imagens do QB e WV-2 e substancial na imagem do IK. Como tem vindo a acontecer, os resultados foram ainda melhores do que nos métodos anteriores, sendo de realçar os ótimos resultados obtidos nas três imagens. Neste método, a imagem do WV-2 foi a que apresentou o melhor resultado, comparando com as outras duas imagens, contrariamente ao que se tinha sucedido nos métodos anteriores, sendo a diferença para a imagem do QB relativamente pequena, cerca de 1%. A imagem do IK foi a que apresentou o pior resultado, apesar de também ter tido um bom resultado. De destacar a enorme melhoria dos resultados nas três imagens, que foram por volta dos 20% comparado com os resultados obtidos no método anterior.

Contrariamente aos métodos de classificação anterior, neste caso serão exibidas as matrizes de confusão obtidas da imagem do QB e do WV-2 por apresentarem um nível de concordância quase perfeito. Já a matriz de confusão obtida da imagem do IK não será exibida por muito pouco, pois a respetiva imagem classificada encontrasse muito perto do nível de concordância desejado. Estas respetivas matrizes de confusão serão representadas em percentagens pelo facto de facilitar a interpretação dos resultados, permitindo assim uma melhor análise (Tabelas 5.7 e 5.8).

Mestrado em Engenharia Geográfica

Departamento de Engenharia Geográfica, Geofísica e Energia

Faculdade de Ciências da Universidade de Lisboa

Tabela 5.7 – Matriz de confusão obtida no método da máxima verossimilhança da imagem do QB.

		Verdade de campo								Total	Inclusão [%]
Classes		No Data	Água	Estradas	Árvores	Relvado	Sequeiro	Construções	Solo Nú		
Classificação	No Data	90.29	5.3	0.48	0	0	0	0.12	0	14.65	1.28
	Água	2.74	94.68	0.28	0	0	0	0.06	0	2.2	22.17
	Estradas	0.56	0	98.81	0	0	0	2.05	0	10.87	7.65
	Árvores	6.39	0	0.01	85.68	0.1	1.18	0.01	0	3.95	27.64
	Relvado	0	0	0	12.79	99.28	8.58	0	0	19.93	3.75
	Sequeiro	0	0	0	1.53	0.62	89.72	0.51	0.38	3.72	10.46
	Construções	0.01	0.03	0.29	0	0	0.52	94.45	0.66	34.21	0.33
	Solo Nú	0	0	0.13	0	0	0	2.8	98.96	10.47	9.79
Total		100	100	100	100	100	100	100	100	100	
Omissão [%]		9.71	5.32	1.19	14.32	0.72	10.28	5.55	1.04		

Tabela 5.8 – Matriz de confusão obtida no método da máxima verossimilhança da imagem do WV-2.

		Verdade de campo								Total	Inclusão [%]
Classes		Estradas	No Data	Árvores	Relvado	Sequeiro	Construções	Solo Nú	Água		
Classificação	Estradas	96.68	1.87	0	0	0	4.87	0.02	0.36	19.36	8.86
	No Data	0.05	95.3	0.02	0	0	0	0	0	2.12	0.54
	Árvores	0.04	1.51	93.08	3.65	0	0.01	0	0.14	8.43	7.16
	Relvado	0	0	6.48	93.25	0.32	0	0	0	14.83	3.75
	Sequeiro	0	0.04	0.41	3.11	99.65	0.01	0.5	0	4.21	14.17
	Construções	3.09	1.28	0	0	0.03	94.98	1.17	0.26	33.24	2.37
	Solo Nú	0.14	0	0	0	0	0.13	98.31	0	16.01	0.44
	Água	0	0	0	0	0	0	0	99.24	1.81	0
Total		100	100	100	100	100	100	100	100	100	
Omissão [%]		3.32	4.7	6.92	6.75	0.35	5.02	1.69	0.76		

Analisando as respetivas matrizes de confusão obtidas, pode-se verificar que os erros de comissão e omissão são muito mais pequenos do que nos métodos anteriores, dando assim origem a estes ótimos resultados. Em relação a estes respetivos erros, os maiores erros de comissão obtidos, em percentagem, foi na classe “árvores”, da imagem do QB, com 28%, na classe “estradas”, da imagem do IK, com 47% e na classe “sequeiro”, da imagem do WV-2, com 14%. Já os maiores erros de omissão obtidos, também em percentagem, foram na classe “árvores”, da imagem do QB e do WV-2, com 14% e 7%, respetivamente e na classe “construções”, da imagem do IK, com 27%. Neste caso, como no método da distância mínima, não houve um relacionamento dos resultados obtidos neste método com os obtidos nos métodos anteriores, excetuando a classe “sequeiro” da imagem do WV-2 que apresentou maior percentagem de pixéis incluídos neste método e no método da distância mínima. Deste modo, pode-se concluir que o comportamento deste algoritmo em relação aos outros já efetuados é diferente, procedendo assim de maneiras diferentes nos mesmos dados.

Em termos globais, as classes que tiveram maior número de pixéis mal classificados foram a classe “árvores”, com 72%, na imagem do QB, a classe “estradas”, com 53%, na imagem do IK e a classe “sequeiro”, com 86%, na imagem do WV-2. Estes resultados devem-se ao facto de muitos pixéis da classe “árvores” terem sido classificados como “relvado” na imagem do QB, muitos pixéis da classe “estradas” terem sido classificadas com “no data” na imagem do IK e muitos pixéis da classe “sequeiro” terem sido classificados como “relvado” na imagem do WV-2. Neste caso, como nos métodos anteriores, não houve uma relação das classes que apresentaram maior número de pixéis mal classificados, não havendo assim uma influência direta do algoritmo nos resultados. De realçar que na imagem do WV-2, a classe “água” teve a totalidade dos pixéis bem classificados.

A imagem final do WV-2 obtida neste método de classificação foi (Figura 5.6):

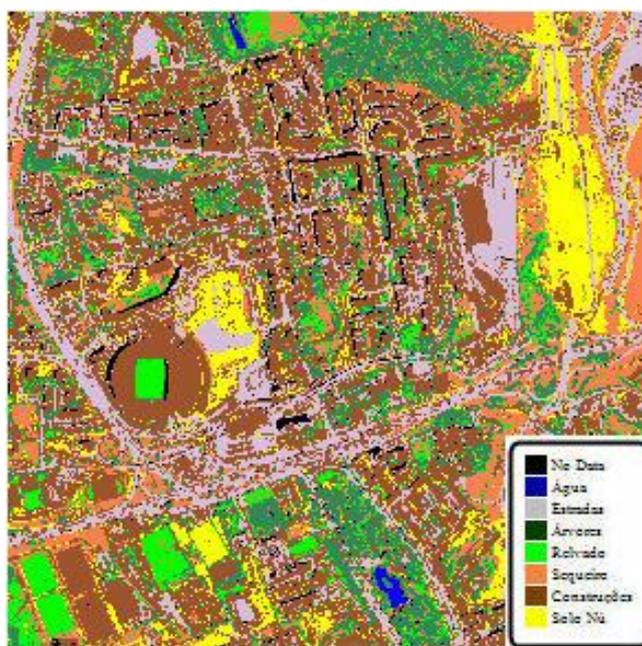


Figura 5.6 – Imagem do WV-2 classificada pelo método da máxima verossimilhança.

Em termos visuais, as imagens classificadas por este método foram bastantes melhores, pois quase todos os elementos da imagem encontram-se devidamente classificados. De realçar que as zonas de maior destaque da área de estudo, como as zonas de água, o estádio de futebol, as zonas arborizadas, as estradas mais predominantes, entre outras foram classificadas quase na perfeição.

5.1.2.5. Método *Spectral Angle Mapper*

Neste método de classificação, os resultados obtidos voltaram a piorar, estando estes na ordem dos 60% de exatidão global. As respetivas exatidões globais, índices Kappa e níveis de concordância obtidos nas matrizes de confusão das três imagens foram (Tabela 5.9):

Tabela 5.9 – Tabela das exatidões globais e índices Kappa obtidos no método SAM das três imagens.

	Exatidão Global [%]	Índice Kappa	Nível de Concordância
QuickBird	64.81	0.5982	Moderado
Ikonos	56.63	0.4947	Moderado
WorldView-2	59.85	0.5364	Moderado

As exatidões globais obtidas neste método de classificação foram 65% para a imagem do QB, 57% para a imagem do IK e 60% para a imagem do WV-2, correspondendo estes resultados a um nível de concordância moderado nas três imagens. De realçar a enorme diminuição dos resultados obtidos comparando com o método anterior, por volta dos 30%. Neste caso, a imagem do QB voltou a ser a imagem que apresentou o melhor resultado, onde a diferença desta para a imagem do WV-2 é apenas de 5%. Apesar da imagem do IK ter sido a que apresentou uma menor diminuição do resultado obtido, cerca de 27%, esta foi a que apresentou o pior resultado comparando com os das outras duas imagens, como já tem sido habitual ao longo deste trabalho.

Como os resultados da classificação voltaram a ser fracos, não será exibida nenhuma matriz de confusão obtida neste método. Analisando as respetivas matrizes de confusão, pode-se verificar também que os erros de comissão e omissão aumentaram, refletindo-se assim nos resultados das classificações. Os maiores erros de comissão obtidos, em percentagem, foram na classe “água”, da imagem do QB, com 71%, na classe “estradas”, da imagem do IK, com 59% e na classe “sequeiro”, da imagem do WV-2, com 39%. Já os maiores erros de omissão obtidos, também em percentagem, foi na classe “construções”, das imagens do QB, do IK e do WV-2, com 74%, 70% e 73%, respetivamente. Como se tinha sucedido nos métodos de classificação da distância mínima e de Mahalanobis, a classe “construções” foi a classe que apresentou maior percentagem de pixéis omitidos em todas as imagens, podendo assim concluir que estes métodos têm muitas dificuldades na classificação de construções, sendo estes uns dos elementos mais difíceis de classificar.

Em termos globais, as classes que tiveram maior percentagem de pixéis mal classificados foram a classe “água”, com 29%, na imagem do QB, a classe “estradas”, com 41%, na imagem do IK e a classe “sequeiro”, com 61%, na imagem do WV-2. Estes resultados devem-se ao facto de muitos pixéis das classes “água” e “estradas” terem sido classificados como “no data”, nas imagens do QB e IK, respetivamente e muitos pixéis da classe “sequeiro” terem sido classificadas com “árvores” na imagem do WV-2. De realçar que nas imagens do IK e do WV-2, as classes “estradas” e “sequeiro”, respetivamente, continuam a ser as classes que tiveram maior percentagem de pixéis mal classificados, como acontece no método anterior. Já na imagem do QB, a classe que teve maior percentagem de pixéis mal classificados passou a ser novamente a classe “água”, como nos métodos da distância mínima e de Mahalanobis. Este método de classificação já tinha sido comparado com estes dois métodos mencionadas nos erros de omissão obtidos, podendo assim confirmar a semelhança do comportamento dos algoritmos nos dados utilizados.

A imagem final do QB obtida neste método de classificação foi (Figura 5.7):

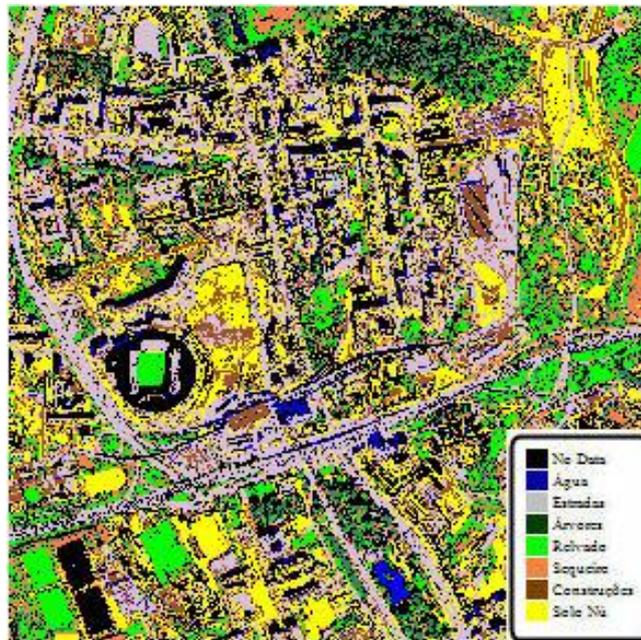


Figura 5.7 – Imagem do QB classificada pelo método SAM.

Comparando esta imagem com as obtidas nos métodos de classificação anteriores, verifica-se que voltou a haver um pior resultado em termos visuais, pois esta contém uma pior representação dos elementos da imagem. Neste caso, são bem visíveis esses elementos mal classificados, como por exemplo, algumas zonas de estrada terem sido classificadas como “água”, o que já tinha ocorrido nos métodos de classificação da distância mínima e de Mahalanobis, o estádio de futebol ter sido classificado como “no data”, entre outros. Este facto para além de ser visível na imagem, também é perceptível na matriz de confusão, pois estas classes apresentam um número muito grande de pixéis mal classificados.

5.1.2.6. Método *Spectral Information Divergence*

Para este método de classificação, os resultados obtidos voltaram a piorar, exceto o da imagem do WV-2, variando estes de 64% a 60% de exatidão global. As respetivas exatidões globais, índices Kappa e níveis de concordância obtidos nas matrizes de confusão das três imagens foram (Tabela 5.10):

Tabela 5.10 – Tabela das exatidões globais e índices Kappa obtidos no método SID das três imagens.

	Exatidão Global [%]	Índice Kappa	Nível de Concordância
QuickBird	53.24	0.4620	Moderado
Ikonos	44.16	0.3608	Razoável
WorldView-2	60.36	0.5471	Moderado

As exatidões globais obtidas neste método de classificação foram 53% para a imagem do QB, 44% para a imagem do IK e 60% para a imagem do WV-2, correspondendo estes resultados a um nível de concordância moderado na imagem do QB e do WV-2 e razoável na imagem do IK. Neste método voltou a haver uma mudança nos melhores resultados obtidos, sendo desta vez, como no método da máxima verossimilhança, a imagem do WV-2 a apresentar o melhor resultado, comparando com as outras duas imagens. A diferença desta para a imagem do QB foi de 7%, sendo de referir que a imagem do WV-2 manteve o resultado, comparado com o método anterior, enquanto a imagem do QB diminuiu cerca de 12%. O resultado da imagem do IK também diminuiu, cerca de 13%, continuando a ser o pior resultado obtidos das três imagens.

Como os resultados desta classificação foram ainda piores que o do método anterior, também não será exibida nenhuma matriz de confusão. Analisando as respetivas matrizes de confusão obtidas, pode-se verificar que os erros de comissão e omissão voltaram a aumentaram, como é perceptível nos resultados obtidos. Os maiores erros de comissão obtidos, em percentagem, foram na classe “água”, da imagem do QB, com 93% e na classe “no data”, das imagens do IK e do WV-2, com 90% e 64%, respetivamente. Já os maiores erros de omissão obtidos, também em percentagem, foram na classe “construções”, das imagens do QB, do IK e do WV-2, com 72%, 85% e 87%, respetivamente. Como se tem vindo a suceder, exceto nos métodos do paralelepípedo e da máxima verossimilhança, a classe “construções” foi a classe que apresentou maior percentagem de pixéis omitidos em todas as imagens, podendo assim confirmar a dificuldade que a maioria das classificações têm em classificar as construções devido à sua diversidade de tipos e cores de telhados.

Em termos globais, as classes que tiveram maior percentagem de pixéis mal classificados foram a classe “água”, com 7%, na imagem do QB e a classe “no data”, com 10% e 36%, respetivamente, na imagem do IK e do WV-2. Estes resultados devem-se ao facto de muitos pixéis da classe “água” terem sido classificados como “no data”, na imagem do QB e muitos pixéis da classe “no data” terem sido classificadas com “água” na imagem do IK e do WV-2. De referir que, na imagem do WV-2, apesar de não ter sido a classe com maior percentagem de pixéis mal classificada, a classe “sequeiro” apresenta valores muito próximo ao da classe “no data”, sendo assim segunda classe com este maior percentagem de pixéis mal classificados. De realçar que na imagem do QB a classe “água” continuou a ser a classe que teve maior percentagem de pixéis mal classificados, como no método de classificação anterior, o que não aconteceu nas imagens do IK e do WV-2, que passou a ser a classe “no data”.

A imagem final do WV-2 obtida neste método de classificação foi (Figura 5.8):

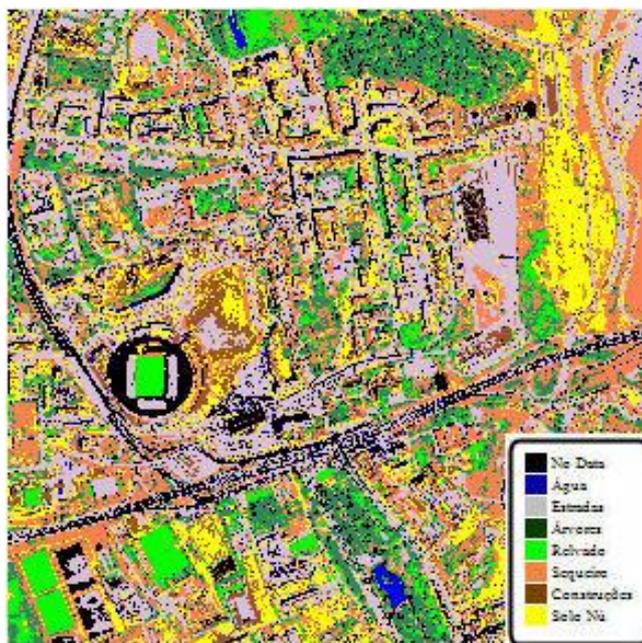


Figura 5.8 – Imagem do WV-2 classificada pelo método SID.

Em termos visuais, pode-se verificar que a imagem do WV-2 obtida neste método de classificação apresentou piores resultados do que a imagem do QB obtida no método anterior, pois esta contém vários elementos mal classificados. Este facto é visível na imagem, sendo de destacar que estradas as mais predominante da área de estudo terem sido classificadas como “no data”. Outro pormenor visível na imagem é a maioria das construções terem sido classificadas como “no data” e “solo nú”. Estes factos também são perceptíveis na matriz de confusão, pois a classe “no data” foi a que apresentou maior percentagem de pixéis mal classificados.

5.1.2.7. Método de codificação binária

Neste último método de classificação, os resultados obtidos pioraram significativamente, variando estes de 39% a 48% de exatidão global. Estes resultados foram uns dos piores resultados obtidos ao longo dos métodos de classificação executados. As respetivas exatidões globais, índices Kappa e níveis de concordância obtidos nas matrizes de confusão das três imagens foram (Tabela 5.11):

Tabela 5.11 – Tabela das exatidões globais e índices Kappa obtidos no método de codificação binária das três imagens.

	Exatidão Global [%]	Índice Kappa	Nível de Concordância
QuickBird	41.95	0.3446	Razoável
Ikonos	39.23	0.2934	Razoável
WorldView-2	48.29	0.3703	Razoável

As exatidões globais obtidas neste método de classificação foram 42% para a imagem do QB, 39% para a imagem do IK e 48% para a imagem do WV-2, correspondendo estes resultados a um nível de concordância razoável nas três imagens. Neste método, a imagem do WV-2 continuou a ser a imagem que apresentou o melhor resultado, comparando com as outras duas imagens, apesar desta ter diminuído cerca de 12%. A diferença desta para a imagem do QB foi aproximadamente igual à do método anterior, cerca de 6%. Por último, o resultado da imagem do IK, apesar de não ter sido o pior resultado obtido neste trabalho, tendo este sido obtido no método do paralelepípedo com 25% de exatidão global, foi a que apresentou o pior resultado, como tem vindo acontecer ao longo deste trabalho.

Analogamente aos métodos anteriores, como os resultados desta classificação foram muito maus, não será exibida nenhuma matriz de confusão. Analisando as respetivas matrizes de confusão obtidas, pode-se verificar que, como é esperado devido aos fracos resultados, existem vários erros de comissão e omissão. Mais especificamente, os maiores erros de comissão obtidos, em percentagem, foi na classe “árvores”, da imagem do QB, com 96%, na classe “no data”, da imagem do IK, com 86% e na classe “sequeiro”, da imagem do WV-2, com 85%. Já os maiores erros de omissão obtidos, também em percentagem, foram na classe “água”, das imagens do QB, do IK e do WV-2, na classe “sequeiro”, das imagens do QB e do IK, na classe “solo nú”, das imagens do QB e do WV-2, na classe “construções”, da imagem do QB e na classe “relvado”, da imagem do IK, com 100% em todas. Desde modo pode-se concluir que, em todas as imagens, a classe “água” foi omitida, pois nenhum destes pixéis foram classificados nos pixéis correspondentes à mesma classe que existe na realidade, o que também aconteceu com as outras classes, que foram mencionadas, nas respetivas imagens. Deste modo, estas respetivas classe têm 0% de pixéis incluídos. Por estes motivos, é compreensível a fraca qualidade dos resultados, pois existem diversos erros nas classificações das classes.

Em termos globais, estes péssimos resultados são facilmente visíveis nas matrizes de confusão obtidas, pois existem várias classes, pré-definidas nas áreas de treino, nas três imagens, que foram eliminadas pelo algoritmo, correspondendo a uma percentagem de 0% de pixéis mal classificados. Mais especificamente, estas classes foram as classes “água”, “sequeiro”, “construções” e “solo nú”, na imagem do QB, as classes “água”, “sequeiro” e “relvado”, na imagem do IK e as classes “água” e “solo nú”, na imagem do WV-2, apresentando assim uma percentagem de 0% de pixéis bem classificados nas imagens. De referir que a classe “água” foi eliminada nas três imagens, podendo assim concluir que o algoritmo tem algumas dificuldades na classificação das zonas de água. Excluindo estas respetivas classes, que foram eliminadas pelo algoritmo, a classe que contém maior percentagem de pixéis mal classificados é a classe a classe “árvores”, com 4%, na imagem do QB, a classe “no data”, com 14%, na imagem do IK e a classe “sequeiro”, com 15%, na imagem do WV-2. Estes resultados devem-se ao facto de muitos pixéis da classe “árvores” terem sido classificados como “relvado”, na imagem do QB e muitos pixéis das classes “no data” e “sequeiro” terem sido classificados como “árvores”, nas imagens do IK e WV-2, respetivamente. Assim sendo, pode-se concluir que este método de classificação tem várias dificuldades em diversas classes, sendo as classificações das zonas de água, de sequeiro e de solo nú as principais zonas que causam maior dificuldades. Comparando este método de classificação com o método do paralelepípedo, que foi o método que obteve os piores resultados a par deste método, conclui-se que este foi o pior método utilizado neste trabalho porque este algoritmo eliminou uma maior percentagem de classes.

A imagem final do WV-2 obtida neste método de classificação foi (Figura 5.9):

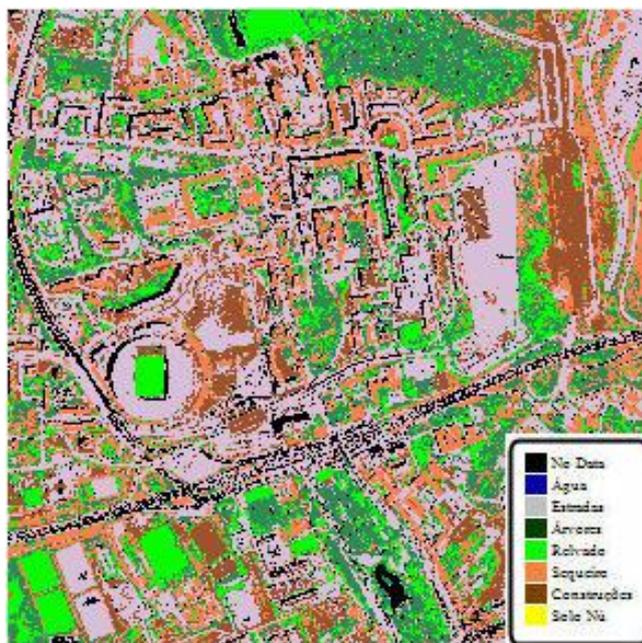


Figura 5.9 – Imagem do WV-2 classificada pelo método de codificação binária.

Em termos visuais, apesar desta imagem parecer representar melhor alguns elementos da imagem, como o caso das árvores e do relvado, esta apresenta piores resultados, pois existe várias classes que foram eliminadas pelo algoritmo e outras que foram mal classificadas. Este facto é facilmente visível na imagem, como é o caso das classes “estradas” e “construções” que se encontram classificados nos elementos errados, e as classes “água” e “solo nú” que não têm nenhum elemento classificado. Também é perceptível na imagem que algumas estradas e as zonas de água estão classificadas com “no data”, algumas construções classificadas com “estradas”, algumas zonas de solo nú classificadas como “construções”, entre outros. A par de imagens obtidas noutros métodos de classificação, esta imagem foi uma das piores obtidas neste trabalho, pois existe vários pixéis mal classificados, como é visível na matriz de confusão.

5.1.3. Árvores de decisão

Neste último tipo de classificação de imagens, após a execução das árvores de decisão, com as respetivas condições de classificação, os resultados obtidos voltaram a melhorar significativamente, estando estes na ordem dos 80% de exatidão global. As suas respetivas exatidões globais, índices Kappa e níveis de concordância obtidos nas matrizes de confusão foram (Tabela 5.12):

Tabela 5.12 – Tabela das exatidões globais e índices Kappa obtidos no método de árvores de decisão das três imagens.

	Exatidão Global [%]	Índice Kappa	Nível de Concordância
QuickBird	86.69	0.8280	Quase Perfeito
Ikonos	81.83	0.7587	Substancial
WorldView-2	89.51	0.8583	Quase Perfeito

As exatidões globais obtidas neste método de classificação foram 87% para a imagem do QB, 82% para a imagem do IK e 90% para a imagem do WV-2, correspondendo estes resultados a um nível de concordância quase perfeito nas imagens do QB e do WV-2 e substancial na imagem do IK. Comparando com os resultados dos métodos anteriores, neste método obtiveram-se resultados muito bons, apesar de não terem sido os melhores resultados do trabalho, tendo estes sido obtidos no método da máxima verossimilhança. Em termos de resultados obtidos neste método, a imagem do WV-2 foi a imagem que apresentou os melhores resultados, comparando com as outras duas imagens, sendo a diferença para a imagem do QB de apenas 3%. Apesar da imagem do IK ter apresentado um bom resultado, esta foi a que obteve o pior resultado neste método de classificação. De referir que apesar de neste método terem sido obtidos resultados menores que no método da máxima verossimilhança, estes são mais precisos por terem em conta diversos tipos de dados auxiliares, sendo eles o nDSM e os respetivos índices de vegetação e não apenas as características espectrais da imagem, como acontece nos métodos de classificação não-supervisionadas e supervisionadas.

Analogamente ao método de classificação da máxima verossimilhança, neste caso serão exibidas as matrizes de confusão obtidas da imagem do QB e do WV-2 por apresentarem um nível de concordância quase perfeito. Já a matriz de confusão obtida da imagem do IK não será exibida por muito pouco, pois a respetiva imagem classificada encontrasse muito perto do nível de concordância desejado. Estas respetivas matrizes de confusão serão representadas em percentagens pelo facto de facilitar a interpretação dos resultados, permitindo assim uma melhor análise (Tabelas 5.13 e 5.14). De realçar que, como explicado no capítulo da metodologia, neste método não foi utilizado a classe “água”, sendo apenas utilizadas as restantes 7 classes.

Mestrado em Engenharia Geográfica

Departamento de Engenharia Geográfica, Geofísica e Energia

Faculdade de Ciências da Universidade de Lisboa

Tabela 5.13 – Matriz de confusão obtida no método da árvore de decisão da imagem do QB.

		Verdade de campo						Total	Inclusão [%]	
Classes		No Data	Sequeiro	Solo Nú	Relvado	Ávores	Estradas			Construções
Classificação	No Data	72.65	0	0	0	0	0.01	5.08	12.01	16.49
	Sequeiro	6.27	13.29	0	0	16.65	0	0.01	1.76	78.19
	Solo Nú	0.05	19.36	97.23	0	0.62	0	1.45	9.89	11.63
	Relvado	0	66.85	0	99.75	20.83	0	0	23.47	10.89
	Árvore	0	0.49	0	0.25	61.54	0	6.15	4.32	56.96
	Estrada	20.55	0	1.22	0	0.24	97.08	0.75	14.29	22.71
	Elevada Const	0.48	0	1.54	0	0.12	2.91	86.56	34.26	1.57
Total		100	100	100	100	100	100	100	100	
Omissão [%]		27.35	86.71	2.77	0.25	38.46	2.92	13.44		

Tabela 5.14 – Matriz de confusão obtida no método da árvore de decisão da imagem do WV-2.

		Verdade de campo						Total	Inclusão [%]	
Classes		Sequeiro	Solo Nú	Relvado	Estradas	Ávores	Construções			No Data
Classificação	Sequeiro	5.93	0.01	3.49	0	35.84	0	0.53	1.28	88.58
	Solo Nú	77.69	90.42	0.19	0.04	0.03	0.94	0	17.81	13.02
	Relvado	1.07	0	92.18	0	16.08	0	0	14.97	1.85
	Estrada	10.26	2.53	0	90.48	0.03	2.62	20.12	21.42	10.49
	Árvore	0.75	0	4.14	0	48	0.42	0	1.59	52.91
	Elevada Const	4.31	7.04	0	9.44	0.03	95.27	2.51	40.59	8.33
	No Data	0	0	0	0.03	0	0.74	76.84	2.34	12.65
Total		100	100	100	100	100	100	100	100	
Omissão [%]		94.07	9.58	7.82	9.52	52	4.73	23.16		

Analisando as respetivas matrizes de confusão obtidas, pode-se verificar que os erros de comissão e omissão foram significativamente maiores do que os do método da máxima verossimilhança, apesar dos resultados das exatidões globais serem parecidos. Em relação a estes respetivos erros, os maiores erros de comissão obtidos, em percentagem, foi na classe “sequeiro”, das imagens do QB, IK e WV-2, com 78%, 99% e 89%, respetivamente. Já os maiores erros de omissão obtidos, também em percentagem, foram na classe “sequeiro”, das imagens do QB, IK e WV-2, com 87%, 100% e 94%, respetivamente. Como mencionado anteriormente, apesar dos bons resultados obtidos, estes respetivos erros de comissão e omissão foram muito elevados, principalmente para a classe “sequeiro”. Neste caso, apenas na imagem do WV-2 é que houve um relacionamento dos resultados obtidos neste método com os obtidos no método da máxima verossimilhança e da distância mínima, sendo a classe “sequeiro” a classe que apresentou maior percentagem de pixéis omitidos em todos estes métodos. Estes elevados erros da classe “sequeiro” devem-se à má definição da condição de determinação da classe, pois apenas neste método é que esta classe foi a que apresentou a maior percentagem de erros nas três imagens.

Em termos globais, a classe que teve maior percentagem de pixéis mal classificados foi a classe “sequeiro”, com 22%, 1% e 11%, nas imagens do QB, IK e WV-2, respetivamente. Estes resultados devem-se ao facto de muitos pixéis da classe “sequeiro” terem sido classificados como “relvado” na imagem do QB e como “solo nú” nas imagens do IK e do WV-2. Neste caso, houve uma relação das classes que apresentaram maior percentagem de pixéis mal classificados, havendo assim uma influência direta da estrutura das árvores nos resultados obtidos. Deste modo, pode-se concluir assim que as árvores de decisão tiveram dificuldades na classificação destas zonas, devido à má definição da respetiva condição. Este facto deve-se às características das imagens do índice de vegetação bNDVI obtidas e ao respetivo valor que foi definido na condição. Como os resultados obtidos foram bons, apesar deste problema da estrutura das árvores, não foi necessário determinar novos valores que adequassem melhor às respetivas condições, pois este trabalho tem como principal objetivo a comparação dos resultados e não o aperfeiçoamento dos mesmos.

A imagem final do WV-2 obtida neste método de classificação foi (Figura 5.10):

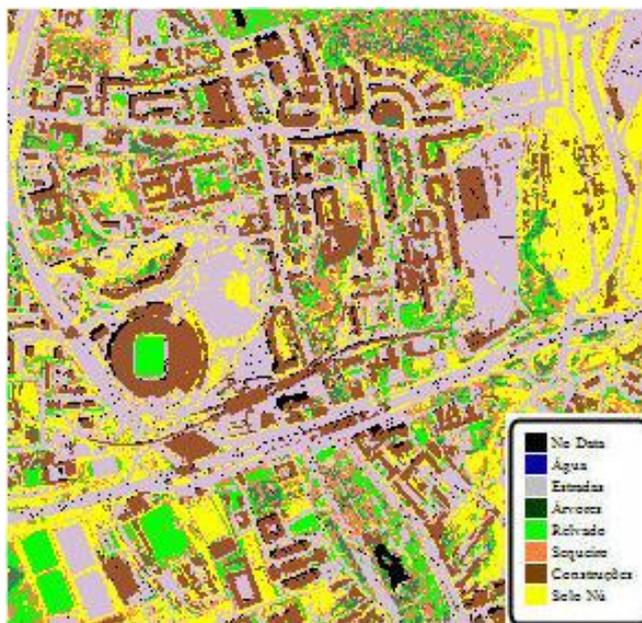


Figura 5.10 – Imagem do WV-2 classificada pelo método da árvore de decisão.

Em termos visuais, a imagem do WV-2 obtida por este método de classificação é muito parecida à obtida no método de classificação da máxima verossimilhança, pois em ambas as imagens quase todos os elementos encontram-se devidamente classificados. De realçar a inexistência da classe “água” por não ter sido definida na estrutura das árvores de decisão, sendo estas classificadas como “no data”. Assim sendo, neste método foram obtidos os melhores resultados de classificação das imagens, a par do método de classificação da máxima verossimilhança.

5.2. Discussão e análise

Nos métodos de classificação não-supervisionadas, a imagem do WV-2 foi a que apresentou melhores resultados, com aproximadamente 65% de exatidão global, estando os resultados obtidos na classificação da imagem do QB muito próximos destes. A classe que causou a maior percentagem de pixéis classificados incorretamente foi a classe “construções”, pois existe diversos tipos e cores de telhado, sendo este um dos principais fatores de erro em qualquer classificação. Um fator muito importante na classificação de imagens é as semelhanças dos valores dos pixéis em elementos diferentes, que impossibilita a sua separação e a devida classificação. Este fator de erro aconteceu neste trabalho, pois existe dois pequenos lagos que contêm os valores dos pixéis muito semelhantes aos valores dos pixéis das sombras, sendo assim agrupados as zonas de água e as sombras numa mesma classe.

Em termos dos métodos utilizados, pode-se verificar que, através dos resultados obtidos, ambos têm um comportamento parecido, pois utilizando as mesmas áreas verdadeiras, os resultados das classificações de cada imagem foram muito parecidos nos dois métodos (Tabela 5.31).

Tabela 5.15 – Exatidões globais obtidas nas classificações não-supervisionadas.

	QB (%)	IK (%)	WV-2 (%)
ISODATA	64.25	50.04	65.39
K-MEANS	62.67	51.14	65.54

Nos métodos de classificação supervisionadas os resultados foram variados, onde a imagem do QB apresentou melhores resultados nos métodos do paralelepípedo, da distância mínima, da distância de Mahalanobis e do SAM e a imagem do WV-2 nos métodos da máxima verossimilhança, do SID e da codificação binária. Como referido anteriormente, a classe “construções” foi a que causou maior percentagem de pixéis classificados incorretamente.

Nestes métodos, contrariamente aos métodos anteriores, um fator preponderante que provoca uma ligeira diferença nos resultados entre imagens é as escolhas das áreas de treino, que são diferentes para cada uma das imagens. Este pode ser um dos fatores da diversidade dos resultados, pois algumas áreas de treino definidas podem adaptar-se melhor a alguns algoritmos do que a outros. Este fator de erro não é facilmente detestável pois é necessário conhecer o comportamento do algoritmo e verificar como se comportaria com as respetivas áreas de treino.

Em termos dos métodos utilizados, pode-se verificar que, através dos resultados obtidos e contrariamente aos métodos de classificação não-supervisionada, todos têm um comportamento diferente, pois utilizando as mesmas áreas de treino e as mesmas áreas verdadeiras, os resultados das classificações de cada imagem foram completamente diferentes. De realçar a qualidade do método da máxima verossimilhança que foi o método que apresentou melhores resultados em todas as imagens, sendo os resultados da imagem do QB e do WV-2, neste método, muito próximos.

O método do paralelepípedo foi o que apresentou maior discrepância de resultados entre imagens, sendo a exatidão global da imagem do QB 61% e a exatidão global da imagem do IK 25%. Possivelmente estas diferenças devem-se ao comportamento do algoritmo nas diferentes áreas de treinos, adaptando-se melhor as áreas de treino da imagem do QB ao algoritmo do que as da imagem do IK. Já o método da máxima verossimilhança foi o método que apresentou melhores resultados em todas as imagens, com aproximadamente 95% de exatidão global nas imagens do QB e do WV-2 e 84% na imagem do IK (Tabela 5.32).

Tabela 5.16 – Exatidões globais obtidas nas classificações supervisionadas.

	QB (%)	IK (%)	WV-2 (%)
Paralelepípedo	61	24.95	40.86
Distância mínima	69.94	51.23	53.39
Mahalanobis	77.39	61.31	73.94
Máxima verossimilhança	95.13	83.68	95.66
SAM	64.81	56.63	59.85
SID	53.24	44.16	60.37
Codificação binária	41.95	39.23	48.29

No método de classificação por árvores de decisão, a imagem do WV-2 foi a que apresentou o melhor resultado com 90% de exatidão global. As exatidões globais obtidas nas imagens do QB e do IK foram 87% e 82% respetivamente. Em termos de números de pixéis bem classificados da classe “construções”, estes foram uns dos melhores obtidos neste trabalho, devido à inserção dos dados altimétricos da área de estudo.

Um problema que pode existir na validação das classificações por árvores de decisão executadas é o facto de os resultados obtidos serem comparados com as áreas de referência, que foram definidas manualmente pelo utilizador, logo contem assim um erro grosseiro associado. Deste modo, é provável que os resultados obtidos estejam mais corretos do que as áreas de referência, já que foram utilizados diversos dados na classificação, tornando-os assim mais credíveis do que os que foram obtidos por apenas com a parte espectral das imagens.

6. Conclusões

Os principais problemas na classificação de imagens são as zonas sombreadas e os edifícios que limitam e dificultam muito os algoritmos de classificação, pois nas zonas sombreadas não é possível classificar devidamente os elementos que se encontram lá representados, tendo estas sido classificadas como “no data” e a diversidade de tipos e cores de telhados condiciona muito a classificação por terem em conta as características espectrais da imagem.

Nas classificações não-supervisionadas executadas neste trabalho, os resultados foram, de grosso modo, os que se esperava, pois a imagem do novo WV-2 apresenta ligeiras melhorias nas classificações de imagens. Já nas classificações supervisionadas que foram executadas, não foi possível concluir se as melhorias na classificação de imagens do satélite WV-2, uma vez que, em alguns algoritmos, a imagem do QB apresentou melhores resultados. Como explicado anteriormente, os resultados em a imagem do WV-2 foi melhor devem-se à melhor resolução espacial da imagem e às novas bandas, melhorando assim a informação do espectro magnético.

Nos métodos de classificação não-supervisionadas pode-se concluir perfeitamente que as três novas bandas da imagem do WV-2 melhoram a classificação da imagem, pois esta apresentou sempre um resultado melhor do que as imagens do QB e do IK. Já no caso dos métodos de classificação supervisionadas essa melhoria não se constatou, pois a imagem do WV-2 só apresentou melhores resultados em apenas três dos métodos executados. Este fator pode dever-se ao facto de o algoritmo ter adaptando-se melhor às áreas de treino escolhidas na imagem do QB do que as que foram escolhidas na imagem do WV-2. Neste tipo de classificação concluiu-se que o método da máxima verossimilhança é o melhor método de classificação de imagens, pois foi neste método que foram obtidos os melhores resultados do trabalho.

Na classificação por árvores de decisão, os dados nDSM foram cruciais para separar os elementos de diferentes elevações, facilitando assim a classificação de algumas classes como as “árvores” e “construção”. Outros dados importantes nesta classificação foram os índices de vegetação que facilitaram muito a discriminação da vegetação e do edificado. Os resultados desta classificação foram muito bons para todas as imagens, o que já era esperado, pois esta tem em conta diversos tipos de dados importantes na discriminação de elementos, como os índices de vegetação e o nDSM, tornando assim mais credíveis os resultados obtidos.

De destacar que, na imagem do WV-2 a classe “sequeiro” foi a classe que apresentou maior percentagem de erros em todos os métodos de classificação, excetuando no método de classificação da distância de Mahalanobis. Mais especificamente, os métodos de classificação que obtiveram maiores percentagens de erros de comissão e omissão desta classe foram nos dois métodos da classificação não-supervisionadas e nas árvores de decisão, enquanto nos métodos de classificação supervisionadas apenas foram obtidos maiores percentagens de erros de comissão desta classe, tendo sido obtidos em todos os métodos deste tipo, excetuando os métodos da distância de Mahalanobis e SID. Enquanto à maior percentagem de pixéis mal classificados desta classe, verificou-se que esta obteve esta maior percentagem exatamente em todos os métodos de classificação executados neste trabalho, excetuando o método da distância de Mahalanobis, como tinha acontecido com os erros de comissão e omissão.

Outra classe que provocou enormes erros em todos os métodos de classificação de imagens foi a classe “construções”, pois em ambiente urbano o número de construções é maior, aumentando assim a variedade de tipos e cores de telhados, o que dificulta as suas respetivas classificações por parte dos algoritmos.

Por fim, uma possível solução para resolver o problema das sombras na classificação de imagens é utilizar séries multi-temporais da mesma zona, onde no entanto, as alterações que podem ocorrer nos dados, que foram adquiridos em diferentes datas, pode provocar erros na classificação.

7. Referências bibliográficas

Chen, Y., Su, W., Li, J., Sun, Z. 2009. Hierarchical object oriented classification using very high resolution imagery and LIDAR data over urban areas. *Advances in Space Research*, 43, p. 1101-1110.

Congalton, R., Green, K., 2009. *Assessing the accuracy of remotely sensed data: principles and practices*. CRC Press, 2nd ed. Boca Raton, FL.

Crisógono, P. 2011. *Deteção remota em meio urbano: teste com classificadores supervisionados a nível do pixel sobre imagens de alta resolução espacial aplicados numa lógica hierárquica de classes*. Dissertação de Mestrado em Gestão do Território, Especialização em Deteção Remota.

Dinis, J., Navarro, A., Soares, F., Santos, T., Freire, S., Fonseca, A., Afonso, N., Tenedório, J., 2010. Hierarchical object-based classification of dense urban areas by integrating high spatial resolution satellite images and LIDAR elevation data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XXXVIII-4/C7.

Doxani, G., Siachalou, S., Tsakiri-Strati, M. 2008. An object-oriented approach to urban land cover change detection. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XXXVII-B7.

Freire, S., Santos, T., Navarro, A., Soares, F., Dinis, J., Afonso, N., Fonseca, A., Tenedório, J., 2010. Extraction of buildings from Quickbird imagery for municipal planning purposes: quality assessment considering existing mapping standards. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XXXVIII-4/C7.

Garcia, S. 2003. *O uso de árvores de decisão na descoberta de conhecimento na área da saúde*. Dissertação de Mestrado em Ciências da Computação.

Ribeiro, S., Scalea, R., Coneglian, F., Oliveira, P. 2009. Classificação supervisionada de imagens orbitais de diferentes resoluções radiométricas. *Anuais XIV Simpósio Brasileiro de Sensoriamento Remoto*, INPE, p. 1013-1020.

Santos, T., Freire, S., Navarro, A., Soares, F., Dinis, J., Afonso, N., Fonseca, A., Tenedório, J., 2010. Extracting buildings in the city of Lisbon using Quickbird images and LIDAR data. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXVIII-4/C7.

Silva, M., Pereira, G. 2007. Avaliação de algoritmos de classificação supervisionada para imagens do Cbers-2 da Região do Parque Estadual do Rio Doce-MG. Anuais XIII Simpósio Brasileiro de Sensoriamento Remoto, INPE, p. 6223-6228.

SulSoft Serviços de Processamento de Dados, Ltd. 2010. Guia do ENVI em Português. Capítulo F.

Zhou, W., Huang, G., Troy, A., Cadenasso, M. 2009. Object-based land cover classification of shaded areas in high spatial resolution imagery of urban areas: A comparison study. Remote Sensing of Environment, 113, p. 1769-1777.