



Classificação automática de zonas verdes para fins de cartografia

Joel Augusto Joanaz D'Assunção Dias

Dissertação para obtenção do Grau de Mestre em
Engenharia Eletrotécnica e de Computadores

Orientadores

Doutor José Manuel Bioucas-Dias

Doutor José Silvestre Serra da Silva

Júri

Presidente: _____

Orientador: _____

Vogais: _____

Outubro de 2015

Agradecimentos

Esta dissertação representa o término de uma etapa, pelo que gostaria de expressar os meus agradecimentos a todas as pessoas e instituições que, direta ou indiretamente, permitiram o meu sucesso nestes últimos seis anos. Em particular, gostaria de agradecer:

Aos meus pais e irmãos pelo apoio, compreensão, motivação, força e coragem ao longo de todo o meu percurso na Academia Militar;

À Academia Militar pelo contributo que teve na minha formação e no meu desenvolvimento enquanto pessoa e soldado;

Aos meus orientadores, Professor José Bioucas-Dias e Professor José Silvestre Silva, pela disponibilidade permanente para esclarecer dúvidas, pela prontidão para ensinar, pela dedicação e empenho irrepreensíveis, pelo constante entusiasmo que transmitiram ao longo de todo o trabalho e pelas pormenorizadas correções durante a escrita da dissertação;

Ao CIGeoE, mais especificamente ao Major Paulo Pires, pelas condições e apoio que me proporcionaram ao longo destes meses de trabalho;

Aos meus camaradas da Academia Militar, especialmente à Nádía Bento e Jorge Pimenta pela amizade e espírito de corpo e pelo inestimável apoio ao longo destes anos.

Resumo

Esta dissertação de mestrado expõe um estudo com o objetivo de discriminar os tipos de vegetação. Uma forma de se obter informações sobre o terreno é através da cartografia, sendo a fotogrametria aérea uma das técnicas mais utilizadas. O objetivo principal deste estudo é o desenvolvimento de uma ferramenta que permita processar fotografias aéreas na banda do visível e que discirna e classifique os diferentes tipos de vegetação.

A metodologia adotada é constituída por três fases principais: extração de características, seleção de características e classificação de imagens recorrendo a dois classificadores, o k-vizinhos mais próximos e a máquina de suporte vetorial. Na primeira fase são extraídas características estatísticas e de textura; na segunda fase implementa-se uma técnica de seleção de características relevantes. A última fase divide-se na otimização dos parâmetros de entrada dos classificadores e posterior classificação das imagens.

Não foi possível a utilização das oito classes pré-definidas devido à similaridade entre algumas delas, pelo que se procedeu à fusão de algumas, resultando em quatro novas classes. Realizou-se a classificação das imagens com as novas classes e comparou-se o desempenho dos dois classificadores. Verificou-se que o melhor classificador é a máquina de suporte vetorial utilizando a função de *núcleo* RBF apresentando 89,8% de classificações corretas. Testou-se a influência do seletor de características e concluiu-se que este conduziu a um aumento médio de 8,25% no desempenho dos classificadores. Conclui-se que os melhores resultados alcançados foram com 10 características para o *K-vizinhos mais próximos* e com 20 características para o *Support Vectorial Machine*.

PALAVRAS-CHAVE: Classificação, Fotografia aérea, Seletor de características, Vegetação

Abstract

This paper presents a study with the purpose of discriminating the different types of vegetation. One way to get information about the land is through cartography, where aerial photogrammetry is one of the most used techniques. The main objective of this thesis is the development of a tool capable of processing aerial photographs on the visible spectrum and for it to be able to discern and classify the different types of vegetation.

The adopted methodology comprises into three major steps: feature extraction, feature selection and image classification using two classifiers, K-Nearest Neighbors and Support Vector Machine. The first step extracts statistical features and features of texture; the second step implements a feature selection technique aimed at selecting the most relevant features and the last step is divided in the optimization of the classifiers input parameters and subsequent image classification.

It was not possible to use the eight classes pre-defined due to the similarity between some of them, which led to the merge of some, resulting in four new classes. The images were classified according the new classes and the performance of the two classifiers was compared. It was found that the best classifier is the Support Vector Machine using the function of kernel Radial Basis Function showing 89,8% of correct classifications. The influence of the feature selector was tested and it was concluded that it led to an average increase [1] of 8,25% in the classifier's performance. It was also concluded that the best results were achieved with 10 features for the K-Nearest Neighbors and with 20 features for the Support Vector Machine.

KEYWORDS: Aerial photography, Classification, Feature Selector, Vegetation

Índice

Agradecimentos	i
Resumo	ii
Abstract	iii
Índice	iv
Lista de Tabelas	vi
Lista de Figuras	vii
Lista de Símbolos	ix
Lista de Acrónimos e Siglas	x
1. Introdução	1
1.1. Enquadramento	1
1.2. Motivação	1
1.3. Objetivos	2
1.4. Estrutura da Dissertação	2
2. Estado de Arte	4
3. Vegetação	7
4. Metodologia	13
4.1. Extração e seleção de características	13
4.2. Parametrização e Classificação	15
4.2.1. Parametrização dos classificadores	15
4.2.2. Classificador KNN	15
4.2.3. Classificador SVM	17
5. Resultados e discussão	19
5.1. Conjunto de dados	19
5.2. Análise do tipo de vegetação	22
5.2.1. Caracterização do conjunto de treino	23
5.2.2. Caracterização do conjunto de teste	25
5.2.3. Classificador KNN	29
5.2.4. Classificador SVM	30
5.2.5. Comparação dos resultados para as imagens de teste	32
5.2.6. Comparação de classificadores	40

5.3.	Recursos computacionais e tempo de processamento	41
6.	Conclusões	44
6.1.	Trabalho futuro.....	45
	Referências	47

Lista de Tabelas

Tabela 5-1: Caraterísticas das imagens originais	23
Tabela 5-2: Impacto da utilização do seletor de características no	30
Tabela 5-3: Impacto da utilização do seletor de características no SVM.....	31
Tabela 5-4: Comparação dos melhores resultados para a imagem A	32
Tabela 5-5: Comparação dos melhores resultados para a imagem B	33
Tabela 5-6: Comparação dos melhores resultados para a imagem C	34
Tabela 5-7: Comparação dos melhores resultados para a imagem D	35
Tabela 5-8: Comparação dos melhores resultados para a imagem E	36
Tabela 5-9: Comparação dos melhores resultados para a imagem F	38
Tabela 5-10: Comparação dos melhores resultados para a imagem G.....	39
Tabela 5-11: O.A. obtida pelos classificadores utilizando 20 características.....	43

Lista de Figuras

Figura 3-1: Representação dos tipos de vegetação existentes em Portugal (adaptado de [10]).....	7
Figura 3-2: Representação das classes “Arvoredo denso”, “Mato denso ou arbustos”, “Pomar” e “Vinha”	8
Figura 3-3: Exemplo de imagens representativas da classe Arvoredo denso: (a) Vista do solo (adaptado de [12]) e (b) Vista aérea	8
Figura 3-4: Exemplo de imagens representativas da classe “Arvoredo esparso”: (a) Vista do solo (adaptado de [13]) e (b) Vista aérea	9
Figura 3-5: Exemplo de imagens representativas da classe “Clareira”: (a) Vista do solo (adaptado de [15]) e (b) Vista aérea	9
Figura 3-6: Exemplo de imagens representativas da classe “Mata”: (a) Vista do solo e (b) Vista aérea	10
Figura 3-7: Exemplo de imagens representativas da classe “Mato denso ou arbustos”: (a) Vista do solo e (b) Vista aérea	10
Figura 3-8: Exemplo de imagens representativas da classe “Pomar”: (a) Vista do solo (adaptado de [16]) e (b) Vista aérea	11
Figura 3-9: Exemplo de imagens representativas da classe “Vinha”: (a) Vista do solo (adaptado de [17]) e (b) Vista aérea	11
Figura 3-10: Exemplo de imagens representativas da classe “Pomar/Vinha”: (a) Vista do solo (adaptado de [19]) e (b) Vista aérea	12
Figura 4-1: Processo utilizado neste metodologia	13
Figura 4-2: Procedimento utilizado pelo KNN para a classificação.....	16
Figura 4-3: (a) Conjunto de dados linearmente separáveis pelo hiper plano (b) Hiper plano ótimo que maximiza a margem (adaptado de [26]).....	17
Figura 5-1: Fusão da classe “Arvoredo denso” (a) com a classe “Mato denso” (b) resulta na classe “Vegetação densa” (c).....	20
Figura 5-2: Fusão da classe “Arvoredo esparso” (a) com a classe “Mata” (b) resulta na classe “Vegetação esparsa” (c).....	20
Figura 5-3: Alteração da classe “Clareira” (a) para a classe “Vegetação escassa” (b).....	21
Figura 5-4: Fusão das classes “Pomar” (a), “Vinha” (b) e “Pomar/Vinha” (c) que resulta na classe “Pomar/Vinha” (d).....	22
Figura 5-5: Imagens representativas de cada classe utilizadas no conjunto de treino	24
Figura 5-6: Legenda	25
Figura 5-7: Representação da Imagem A (a) e respetiva classificação manual (referência) (b)	25
Figura 5-8: Representação da Imagem B (a) e respetiva classificação manual (referência) (b)	26
Figura 5-9: Representação da Imagem C (a) e respetiva classificação manual (referência) (b)	26
Figura 5-10: Representação da Imagem D (a) e respetiva classificação manual (referência) (b)	27
Figura 5-11: Representação da Imagem E (a) e respetiva classificação manual (referência) (b)	27
Figura 5-12: Representação da Imagem F (a) e respetiva classificação manual (referência) (b)	28

Figura 5-13: Representação da Imagem E (a) e respectiva classificação manual (referência) (b)	28
Figura 5-14: Resultados obtidos com o classificador KNN	29
Figura 5-15: Resultados obtidos com o classificador SVM	31
Figura 5-16: (a) Imagem A; (b) classificação de referência; (c) classificação obtida com o KNN; (d) classificação obtida com o SVM.....	32
Figura 5-17: (a) Imagem B; (b) classificação de referência; (c) classificação obtida com o KNN; (d) classificação obtida com o SVM.....	33
Figura 5-18: (a) Imagem C; (b) classificação de referência; (c) classificação obtida com o KNN; (d) classificação obtida com o SVM.....	35
Figura 5-19: (a) Imagem D; (b) classificação de referência; (c) classificação obtida com o KNN; (d) classificação obtida com o SVM.....	36
Figura 5-20: (a) Imagem E; (b) classificação de referência; (c) classificação obtida com o KNN; (d) classificação obtida com o SVM.....	37
Figura 5-21: (a) Imagem F; (b) classificação de referência; (c) classificação obtida com o KNN; (d) classificação obtida com o SVM.....	38
Figura 5-22: (a) Imagem G; (b) classificação de referência; (c) classificação obtida com o KNN; (d) classificação obtida com o SVM.....	40
Figura 5-23: Resultados médios dos classificadores	41
Figura 5-24: Tempo de processamento, em segundos, necessário para classificar cada imagem de teste.....	42

Lista de Símbolos

Símbolos Romanos

C	Parâmetro de penalidade do erro
d	Deslocamento entre píxeis
G	Níveis de cinzento
k	Número de vizinhos
K	Número de classes
L	<i>Núcleo</i> linear
R	<i>Núcleo</i> gaussiano
$\bar{x}$	Média
X	Conjunto de treino
Z	Conjunto de teste

Símbolos Gregos

γ	Coeficiente do <i>núcleo</i>
θ	Orientação [°]
Σ	Somatório
σ	Desvio Padrão

Lista de Acrónimos e Siglas

BFS Back Feature Selection

GB Gigabyte

GHz Gigahertz

GLCM Gray Level Co-occurrence Matrix

CIGeoE Centro de Informação Geoespacial do Exército

KNN K-Nearest Neighbor

MPL Multilayer Perceptron

NDVI Índice de Vegetação por Diferença Normalizada

PCA Principal Component Analysis

RAM Random Access Memory

RBF Radial Basis Function

RGB Red, Green e Blue

ROI Region of Interest

SVM Support Vector Machine

1. Introdução

Este capítulo apresenta uma visão geral da dissertação de mestrado, assim como a sua estrutura. É constituído por quatro fases, a primeira faz um enquadramento do tema abordado e a sua importância enquanto área de investigação, de seguida são referidos os motivos que conduziram à realização deste trabalho. Posteriormente são apresentados os objetivos que se pretendem alcançar com a realização desta dissertação e por último é apresentada uma descrição da estrutura presente nesta dissertação, assim como uma explicação sumária do conteúdo que cada capítulo aborda.

1.1. Enquadramento

Esta dissertação de mestrado apresenta um estudo cujo objetivo é a discriminação de alguns tipos de vegetação.

Uma forma de se obter informações sobre o terreno é através da cartografia. Uma das técnicas que tem assumido um papel fundamental para a cartografia é a fotogrametria aérea, a qual permite efetuar medições rigorosas a partir de fotografias aéreas. A aquisição de fotografias aéreas revela uma elevada importância quando é escassa ou inexistente a informação cartográfica relativa ao terreno ou não é possível a obtenção da mesma através de outros métodos. A obtenção de fotografias aéreas é efetuada durante os voos e consoante o tipo de câmara utilizado é possível obter fotografias com informações na banda do visível ou multiespectrais. Com base nos dados das fotografias é possível extrair características do terreno. Em Portugal, o Centro de Informação Geoespacial do Exército (CIGeoE) é a entidade por excelência que realiza a produção cartográfica. A interpretação da informação extraída a partir das fotografias aéreas é realizada por equipas de fotogrametristas devidamente especializadas, sendo inserida na base de dados geográfica do CIGeoE após validação no terreno.

1.2. Motivação

A criação e implementação de algoritmos que permitam a discriminação do coberto vegetal é uma área em franco crescimento por parte da comunidade científica. Muitas das ferramentas já desenvolvidas possibilitam o controlo de fronteiras, a identificação de diferentes espécies de vegetação e o controlo da desflorestação, através do uso de métodos de aprendizagem automática, o que motivou à realização desta dissertação. Uma vez que no CIGeoE os dados extraídos das fotografias aéreas são interpretados por fotogrametristas devidamente especializados, este procedimento demora algum tempo a ser executado, podendo ser de alguns dias ou mesmo semanas. Esta tese tem como objetivo a criação de algoritmo que interprete os dados provenientes

das fotografias aéreas, de forma automática ou semiautomática, introduzindo uma baixa taxa de erros e principalmente um consumo de tempo muito inferior ao despendido na interpretação manual.

1.3. Objetivos

Esta dissertação tem como principal objetivo o desenvolvimento de uma metodologia, que através do processamento de fotografias aéreas, extraia informações que permitam a discriminação dos diferentes tipos de vegetação, através da aplicação de classificadores automáticos, com baixa probabilidade de erro. Como objetivo secundário, pretende-se proceder à comparação da precisão global que os classificadores implementados obtêm, assim como a influência que os métodos de seleção de características têm nos resultados alcançados nas diferentes imagens estabelecidas.

1.4. Estrutura da Dissertação

A presente dissertação encontra-se organizada em 6 capítulos: Introdução, Estado de arte, Vegetação, Metodologia, Resultados e discussão e Conclusões.

No capítulo 2 é realizada uma análise da investigação científica existente nesta área de estudo, no que diz respeito às principais aplicações ou algoritmos desenvolvidos e/ou estudados por outros autores na resolução de problemas de classificação que estejam relacionados com a discriminação de tipos e/ou espécies de vegetação, deteção de viaturas, edifícios e pessoas. Este capítulo tem como objetivo indicar o caminho a seguir para o desenvolvimento da metodologia a ser elaborada nesta dissertação.

No capítulo 3 é elaborada uma descrição sobre a influência que tanto o oceano Atlântico como o mar Mediterrâneo provocam nas características da vegetação existente em Portugal. Aborda também as oito classes definidas e utilizadas, pelos fotogrametristas do CIGeoE, para classificar os diferentes tipos de vegetação presentes nas zonas verdes das imagens, que foram delimitadas através da análise das fotografias aéreas ortorrectificadas.

O capítulo 4 aborda a metodologia adotada neste trabalho; começa pela explicação de cada uma das características que são extraídas das imagens que foram fornecidas pelo CIGeoE; de seguida aborda o método usado para a seleção das mesmas; continua com uma exposição da abordagem usada para se obter os valores dos parâmetros que permitem otimizar a precisão dos classificadores; culminando com uma descrição teórica do funcionamento de cada um dos classificadores utilizados para resolver o problema proposto, de forma a poderem ser implementados, permitindo assim, atingir os objetivos estabelecidos.

No capítulo 5 expõem-se e discutem-se os resultados obtidos através da implementação da metodologia adotada. Inicialmente é apresentado e descrito o conjunto de dados que foi usado neste trabalho, refere-se as zonas de vegetação analisadas, assim como os conjuntos de treino e teste que foram definidos para a aprendizagem dos classificadores e posterior extração de resultados. De

seguida são apresentados os resultados obtidos por cada classificador, é calculada a influência da utilização de um seletor de características nos resultados e são discutidos todos os resultados obtidos para cada uma das imagens selecionadas. Por último é feita uma comparação dos recursos computacionais exigidos por cada classificador.

No capítulo 6 apresentam-se as conclusões deste trabalho, realizando-se uma análise geral das diversas partes do trabalho desenvolvido, como a metodologia implementada e os resultados obtidos. São descritos possíveis aspetos a melhorar para a possível obtenção de melhores resultados. Sugere-se também trabalhos futuros que possam ser realizados no âmbito desta dissertação, assim como a possível aplicabilidade deste trabalho.

2. Estado de Arte

O mapeamento da vegetação é praticado em grande parte do globo, existindo numerosos métodos que ao longo de várias décadas têm continuado a evoluir e a adaptar-se aos diversos tipos de vegetação que são encontrados [1].

Alguns dos métodos mais utilizados são a interpretação da fotografia aérea (*Aerial Photography Interpretation* - API), a análise da imagem com base em píxeis (*Pixel-based Image Analysis* - PBIA) e a análise da imagem com base em objetos geográficos (*Geographic Object-based Image Analysis* - GEOBIA). O primeiro, API, requer uma interpretação estereoscópica manual de pares de fotografias aéreas, sendo por isso um método moroso, dispendioso e pouco eficiente. No entanto, continua a ser utilizado em numerosas aplicações. O PBIA atribui a cada píxel uma classe de acordo com as suas características estatísticas. O GEOBIA, por outro lado, primeiro agrupa ou segmenta os píxeis vizinhos com características idênticas e só depois atribui uma classe a cada segmento.

Lewis *et al* [2] compara 7 métodos: um método API, dois métodos PBIA e quatro métodos GEOBIA, no qual se obtém uma precisão que varia dos 28% aos 67%. A API obtém a precisão mais elevada (67%) em mapas com escala 1:25000, e o PBIA obtém a pior (28%) quando aplicado ao Landsat5 TM com escala 1:25000. Conclui-se então que apesar de o API ser o mais dispendioso é o que produz melhores resultados, enquanto o PBIA é o mais barato, porém gera os piores resultados.

Nathalie Long *et al* [3] compara as diferenças entre uma abordagem *pixel-based* (*Pixel-based Approach* - PBA) e uma abordagem *object-based* (*Object-based Approach* - OBA) na deteção de superfícies verdes em áreas urbanas. Assim como a influência da resolução espacial das imagens para a deteção de vegetação, sendo utilizados dois tipos de imagens, multiespectrais (verde, vermelho e infravermelho próximo) com uma resolução espacial de 10m e imagens de alta resolução (*Very High Resolution* - VHR) com 2,5m de resolução espacial. Na classificação PBA é usada a máxima verosimilhança e na classificação OBA é feita uma segmentação de 3 níveis e aplicada uma classificação hierárquica. Os limiares de classificação são definidos através de 4 características: homogeneidade GLCM (*Grey Level Co-Occurrence Matrix*), Índices de Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index* - NDVI), BSI (*Brilliance Soil Index*) e forma. Posteriormente é utilizado o MSI (*Map Similarity Index*) de forma a serem comparados os resultados obtidos entre as duas abordagens. A precisão global obtida oscila entre os 89% e os 91% dependendo das imagens e da abordagem utilizada. Com base nos resultados obtidos conclui-se que a classificação OBA em imagens VHR é a mais adequada em imagens com zonas de elevada densidade urbanística assim como com edifícios altos. Por outro lado, a deteção de vegetação deveria ser mais precisa em zonas rurais usando o mesmo método, mas tal não é verificado, uma vez que a classificação PBA apresenta uma melhor precisão relativamente à OBA.

Laliberte *et al* [4] propõe métodos com base na análise de imagens baseadas em objetos (OBIA) de forma a classificar os diversos tipos de vegetação nas regiões áridas do sudoeste dos Estados Unidos da América, tendo por bases imagens aéreas multiespectrais (visível e infravermelho próximo) de dimensão 13824x7680 píxeis, cada um representando 4 centímetros. O processo inicia-se com uma segmentação da imagem em áreas homogêneas utilizando 3 parâmetros (escala, cor e

forma) cada um com um peso entre 0 e 1. São extraídas 4 características: valor da intensidade dos pixels, NDVI, média e rácio das 3 bandas. Posteriormente são utilizados 2 classificadores, o *rule-based* que utiliza duas características: valor de intensidade dos pixels e NDVI, e o classificador k-vizinhos mais próximos (*K-Nearest Neighbors* - KNN) que utiliza 3 características: NDVI, média e rácio das 3 bandas.

Zhengrong Li *et al* [5] descrevem um método que consiste na utilização de um descritor resultante da fusão de cor e textura com o intuito de classificar as diferentes espécies de árvores. Desenvolve uma segmentação automática para detetar e delinear as copas das árvores eliminando o resto, extraindo o histograma de cores e o descritor de textura (*Uniform Local Binary Patterns* - ULBP). Posteriormente aplica o *Principal Component Analysis* (PCA) de forma encontrar as relações não lineares das características de cor e textura extraídas. Depois é utilizada a máxima verosimilhança de forma a estimar qual o melhor conjunto de características que devem ser usadas no classificador Máquina de Suporte Vetorial (*Support Vector Machine* - SVM). Utilizado em imagens aéreas de alta resolução, com tamanho dos pixels de 15 centímetros.

Para poder avaliar este método os autores aplicam o mesmo método, mas com as características separadas. De onde se obtém uma precisão na classificação de 80,2% para a cor e 71,1% para a textura. O método da fusão, por outro lado, obtém uma precisão de 83,5%, valor que confirma que a fusão permite obter melhores resultados.

Chapman *et al* [6] sugere uma solução para a classificação da vegetação usando fotografias aéreas orto retificadas multiespectrais com uma resolução espacial de 5 metros. Destas imagens é retirado um conjunto de características que são usadas num método que consiste em árvores de regressão e classificação permitindo definir as regras para a classificação. Para o cálculo destas regras recorre-se a um método recursivo que faz a partição binária dos dados até que sejam obtidas regiões homogêneas, também designadas por nós, cada uma com a informação de uma classe. São definidas sete classes de vegetação e é aplicado o classificador *Random Forest*, de forma a ser efetuada uma classificação hierárquica. Este método permitiu obter uma precisão de 97% em classificações corretas.

U. Bradter *et al* [1] apresenta um estudo sobre classificação de vegetação utilizando imagens aéreas orto retificadas na banda do visível com uma resolução espacial de 5 metros, no Parque Nacional de Yorkshire Dales em Inglaterra. O objetivo foi pesquisar a influência do uso de variáveis físicas, elevação, inclinação e tipo de solo, na eficácia das classificações. São extraídas 3 características das imagens: média dos valores de intensidade dos pixels em cada banda, rácio entre os valores médios calculados anteriormente e uma medida de heterogeneidade da intensidade espectral. Estas características são introduzidas no classificador *Random Forest*, de onde se obtém uma precisão entre os 87% e os 92%.

Myint *et al* [7] testa a eficiência dum classificador baseado em objetos na classificação de zonas urbanas, recorrendo apenas à informação espectral provenientes de imagens do satélite *QuickBird*. Obtém uma precisão global de cerca de 63,33% apenas com esta informação. De seguida aplica cinco métodos diferentes para o paradigma do *object-based* que, em diferentes escalas, separa espacialmente e espectralmente os pixels semelhantes. Com esta informação a precisão

global do classificador *object-based* atinge os 90,4%, enquanto que o classificador da máxima verossimilhança apenas atinge uma precisão global de 67,6%. É então demonstrado que o um classificador baseado em objetos proporciona uma abordagem significativamente melhor que os clássicos classificadores *per-pixel*.

Minho *et al* [8] utiliza uma abordagem GEOBIA em imagens aéreas com 30 cm de resolução espacial para classificar pântanos em três classes, vegetação, canal e lama. Investiga três problemas de classificação associados à escala usada na segmentação, são eles a comparação entre a utilização da GEOBIA com uma ou várias escalas, o benefício de incorporar a informação sobre texture proveniente das GLCM e por último, o efeito da utilização de níveis de quantização nas GLCM. Concluiu que, relativamente ao primeiro problema, a abordagem multi-escala ultrapassa a abordagem com apenas uma escala, obtendo uma precisão global de 82% contra os 76% obtidos com uma escala. A adição da textura melhora a discriminação espectral e leva a um aumento na precisão da classificação de 3% até 12% quando incluído na abordagem multi-escala. No que toca ao terceiro problema, concluiu que a utilização de apenas dois níveis de quantização induz a obtenção de melhores classificações.

3. Vegetação

A vegetação consiste no conjunto de plantas de uma determinada região que têm uma fisionomia e composição influenciada pelo ambiente, especialmente o relevo e o clima. Em Portugal, devido a estes dois fatores existem duas grandes regiões, a de vegetação de origem Atlântica e a de vegetação de origem Mediterrânica.

A vegetação de origem Atlântica, situada a Norte, é caracterizada por espécies de folha caduca típicas da Europa Oceânica. Tem como espécies características o castanheiro, o carvalho, o ulmeiro e o pinheiro-bravo. Na vegetação de origem Mediterrânica, a Sul, predominam as espécies de folha perene e com adaptações xerofíticas, típicas das zonas da bacia do Mediterrâneo. O sobreiro, a azinheira, o pinheiro-manso, o loureiro e algumas plantas aromáticas são algumas das espécies características [9]. Na Figura 3-1 está representada a distribuição da vegetação existente no nosso país.




Figura 3-1: Representação dos tipos de vegetação existentes em Portugal (adaptado de [10])

No CIGeoE, com base na análise visual de fotografias aéreas ortorrectificadas, a vegetação é classificada em oito classes utilizando *software* SIG (Sistema de Informação Geográfica), como por exemplo o *software* de código aberto QGIS. As classes utilizadas são as seguintes: arvoredado denso,

arvoredo esparsa, clareira, mata, mato denso ou arbustos, pomar, vinha e pomar/vinha. Na Figura 3-2, é representada uma fotografia aérea com algumas das classes usadas pelo CIGeoE.





Figura 3-2: Representação das classes “Arvoredo denso”, “Mato denso ou arbustos”, “Pomar” e “Vinha”

A classe “Arvoredo denso” representa áreas constituídas maioritariamente por espécies de árvores perenes como por exemplo os pinheiros e os eucaliptos. São áreas em que, através da imagem aérea, não é possível visualizar o solo devido à elevada densidade de árvores e/ou devido a estas possuírem copas de grandes dimensões que se sobrepõem entre si. Estas áreas existem predominantemente no Norte do país e correspondem a cerca de 16,87% do território nacional, o que corresponde a 1,526 milhões de hectares [11]. Na Figura 3-3 é demonstrado um exemplo desta classe.



(a)



(b)

Figura 3-3: Exemplo de imagens representativas da classe Arvoredo denso: (a) Vista do solo (adaptado de [12]) e (b) Vista aérea

A segunda classe usada é o “Arvoredo esparsa”. Esta classe abrange as zonas verdes que contém árvores de grandes dimensões dispersas pelo terreno, é possível observar o solo nas fotografias aéreas. São áreas de clima seco, onde imperam as planícies extensas e serras pouco elevada, características relacionadas com a influência do Mediterrâneo, sendo por isso áreas, na sua maioria, situadas a Sul. As espécies observadas nestas zonas são predominantemente o sobreiro e a azinheira, ocupam cerca de 8,1%, equivalente a 737 mil hectares, do território português [11].



(a)



(b)

Figura 3-4: Exemplo de imagens representativas da classe “Arvoredo esparsa”:

(a) Vista do solo (adaptado de [13]) e (b) Vista aérea

A “Clareira” é a terceira classe utilizada. Representa zonas dentro da floresta ou bosque, que devido a causas naturais ou por intervenção humana, contém pouca ou nenhuma vegetação. Essa vegetação é essencialmente constituída por arbustos. Algumas das causas para a sua criação são o fogo natural ou propositado, o corte de árvores e o solo estéril. Estas zonas são importantes para a vida animal proporcionando-lhes contacto com a luz solar e local de alimentação diferente da existente na floresta [14].



(a)



(b)

Figura 3-5: Exemplo de imagens representativas da classe “Clareira”:

(a) Vista do solo (adaptado de [15]) e (b) Vista aérea

Como quarta classe, temos a “Mata”. Esta classe à semelhança da classe “Arvoredo Esparso” representa locais com uma baixa densidade de vegetação, sendo possível observar o solo. Porém estas áreas não são constituídas por árvores, mas sim por arbustos. Arbusto é um vegetal lenhoso de porte variável com uma dimensão inferior a 6 metros. São áreas onde geralmente não ocorre intervenção humana e muitas vezes associadas a locais de difícil acesso, como por exemplo encostas.



(a)



(b)

Figura 3-6: Exemplo de imagens representativas da classe “Mata”:

(a) Vista do solo e (b) Vista aérea

A próxima classe utilizada é “Mato denso ou arbustos” e é caracterizada por apresentar dois tipos de vegetação distintos. Um deles contém uma grande densidade de vegetação com um porte médio/baixo enquanto que o outro contém vegetação esparsa de porte médio. Ambos são constituídos por plantas não cultivadas, também conhecidas por tojos, e arbustos, daí a denominação de mato. Estas áreas têm origem natural e podem aparecer em locais de cultivo que tenham sido abandonados à alguns meses e/ou anos.



(a)



(b)


Figura 3-7: Exemplo de imagens representativas da classe “Mato denso ou arbustos”:

(a) Vista do solo e (b) Vista aérea

A sexta classe é o “Pomar”. Pomar designa um conjunto de árvores frutíferas ou o terreno onde estas são cultivadas em quantidade. São terrenos cultivados pelo homem podendo conter uma ou mais espécies de árvores de fruto, como por exemplo a pereira, a macieira, a oliveira, etc. O terreno apresenta uma característica bastante peculiar que é o facto de ser constituído por fileiras de árvores paralelas entre si com uma distância que varia entre os 2 e os 5 metros. Em cada fileira a distância depende da espécie plantada. A Figura 3-8 apresenta dois exemplos de um pomar, à esquerda a vista aérea e à direita a vista a partir do solo.



(a)



(b)


Figura 3-8: Exemplo de imagens representativas da classe “Pomar”:

(a) Vista do solo (adaptado de [16]) e (b) Vista aérea

A “Vinha” representa a sétima classe utilizada. Apresenta características bastante similares à classe anterior, diferindo essencialmente na espécie cultivada, a videira. Portugal é o 7º país do mundo com maior área de vinha, com cerca de 239 mil hectares, porém, a relação entre a área de vinha e a área total do país, coloca Portugal no 1º lugar a nível mundial, com aproximadamente 2,59% de área ocupada com vinha [17]. As principais regiões vinícolas em Portugal são: Minho, Douro, Bairrada, Valpaços, Alentejo, Bucelas, Colares, Carcavelos, Setúbal, Algarve e Madeira.



(a)



(b)

Figura 3-9: Exemplo de imagens representativas da classe “Vinha”:

(a) Vista do solo (adaptado de [17]) e (b) Vista aérea

A última classe tem a designação de “Pomar/Vinha”. Esta classe é uma combinação das duas classes anteriores e é utilizada para representar os minifúndios, terrenos com pouco mais de 5 hectares e usualmente associadas ao cultivo de diversas espécies destinadas ao autossustento. Estes terrenos existem essencialmente nas seguintes zonas: Madeira, Beira Litoral e entre Douro e Minho [18].



(a)



(b)

Figura 3-10: Exemplo de imagens representativas da classe “Pomar/Vinha”:

(a) Vista do solo (adaptado de [19]) e (b) Vista aérea

Este capítulo teve como objetivos a definição do conceito de vegetação, a apresentação de uma breve explicação sobre as influências que o clima e o terreno têm na vegetação existente, que divide o país em duas grandes zonas, Portugal Atlântico e Portugal Mediterrânico. De seguida são expostas, explicadas e exemplificadas as oito classes que o CIGeoE utiliza para caracterizar as zonas de vegetação presentes no nosso país.

4. Metodologia

Neste capítulo são descritos os métodos utilizados na elaboração da solução para a discriminação dos diferentes tipos de vegetação. Este trabalho adota, de uma forma geral, a metodologia usada para a resolução de um problema de reconhecimento de padrões, neste caso, a classificação de imagens. A classificação é um processo usado para reduzir as imagens em diversas áreas comuns, denominadas de classes.

O CIGeoE forneceu as fotografias aéreas, as quais foram examinadas com o objetivo de extrair regiões de interesse, distintas entre si, representativas de cada classe. Estas são divididas em regiões de menor dimensão de forma a calcular-se as características que constituirão o conjunto de treino a ser usado. O conjunto de treino é um vetor de amostras, cada uma contém o conjunto de características calculadas e a classe a que pertence.

Procede-se à extração de características de primeira e segunda ordem, nomeadamente média, mediana, desvio padrão e variância. De segunda ordem temos as matrizes de coocorrência. De seguida, é implementada uma técnica para estimar os parâmetros de entrada dos classificadores, denominada de *GridSearchCV*. Após a estimação dos parâmetros procedeu-se à classificação das imagens utilizando dois classificadores diferentes, o k-vizinhos mais próximos e a máquina de suporte vetorial.

Classifica-se as imagens usadas manualmente, através de análise visual das diversas classes. Posteriormente realiza-se a comparação entre os resultados dos classificadores e a classificação manual (referência) de forma a calcular o desempenho dos classificadores. Na Figura 4-1 está esquematizado todo este processo.




Figura 4-1: Processo utilizado nesta metodologia

4.1. Extração e seleção de características

Um dos processos mais importantes nos problemas de classificação é a extração das características. Neste caso, as imagens são transformadas de *Red Green Blue* (RGB) para Matiz, Saturação e Valor, *Hue Saturation Value* (HSV), e para escala de cinzento (*Greyscale*), isto porque umas características baseiam-se no valor da intensidade dos píxeis da imagem, enquanto outras dependem dos níveis de cinzento dos mesmos. As características extraídas, são:

A primeira característica extraída foi a média aritmética, equação (3.1), em que n representa o número de píxeis da região de interesse (*Region Of Interest* – ROI) e x_i representa o valor de intensidade do píxel i , com $i = 1, \dots, n$.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.1)$$

A segunda característica extraída foi a mediana, que analisa o vetor ordenado que contém todos os píxeis da ROI e calcula o seu valor de intensidade central.

A terceira característica extraída denomina-se de desvio padrão e permite obter a variação dos valores dos píxeis relativamente ao valor médio, é expressa pela equação (3.2):

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (3.2)$$

A variância, representada por σ^2 , é a quarta característica. Estas 4 características são calculadas para cada uma das três bandas da imagem, HSV, o que produz 12 características.

É também calculado o valor máximo de intensidade de cada ROI assim como a diferença entre o valor mínimo e máximo da intensidade dos píxeis, estes são, respetivamente, a quinta e sexta características extraídas.

A informação sobre a textura da imagem é obtida com recurso à extração de características de segunda ordem que utilizam matrizes de coocorrência dos níveis de cinzento (GLCM). Através destas pode-se calcular as características tendo como base a relação entre os G níveis de cinzento que descrevem a imagem segundo um deslocamento d e uma orientação θ° [20]. Optou-se por usar 256 níveis de cinzento, $d = \{1, 2, 3\}$ e $\theta = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$; calcula-se as matrizes de coocorrência para cada ROI e com base nestas são calculadas as seguintes características: Contraste, Energia, Homogeneidade, Correlação, Dissimilaridade e Segundo momento angular.

Depois de extraídas as características é constituído o conjunto de treino e estas são processadas com o objetivo de se escolher as mais relevantes para a distinção das classes previamente definidas.

De seguida procede-se à seleção das características, que representa um passo importante, uma vez que muitas delas são redundantes e/ou estão correlacionadas entre si. Porém, se o conjunto de treino tiver dimensões reduzidas, a utilização de um elevado número de características limita a capacidade de generalização dos classificadores [21]. Nesta dissertação utiliza-se um algoritmo, denominado *Back Feature Selection* (BFS), que permite selecionar o número de características independentemente do classificador a implementar. Este algoritmo inicia a seleção de características com um conjunto com todas as características e iterativamente elimina as menos relevantes [22].

4.2. Parametrização e Classificação

Para se proceder à classificação do coberto vegetal utiliza-se métodos de classificação multiclasse supervisionada. O classificador é, um algoritmo que com base no conjunto de treino (conjunto de pares vetor de característica-classe) atribui classes a novos dados. A estes novos dados, que inicialmente não possuem uma classe atribuída, é atribuído o nome de conjunto de teste.

Nesta fase, o objetivo é definir os parâmetros dos classificadores para que, atribuído um conjunto de treino com n amostras das K classes, estes tenham a capacidade de distinguir as diferentes classes aquando da introdução de uma nova imagem. São implementados dois classificadores: KNN e a SVM.

4.2.1. Parametrização dos classificadores

A parametrização dos classificadores é uma fase bastante importante, uma vez que permite identificar valores ótimos dos parâmetros, que portanto minimizam a probabilidade de erro. Esta parametrização foi realizada com base numa técnica, denominada de *GridSearchCV*. Esta técnica pertence à biblioteca do *scikit-learn*¹ e consiste numa busca exaustiva sobre os diversos valores dos parâmetros fornecidos para um determinado classificador, no caso do KNN, é o número de vizinhos (parâmetro k) e no caso do SVM são os parâmetros C e γ . No caso concreto desta técnica, a busca é otimizada através da implementação de uma outra técnica, denominada de validação cruzada *K-fold*.

A validação cruzada *K-fold* consiste em dividir o conjunto de dados em k subconjuntos, todos com a mesma dimensão. Iterativamente, cada subconjunto é constituído como conjunto de teste e os $k - 1$ restantes são utilizados como conjuntos de treino e é calculada uma medida de desempenho como por exemplo a precisão.

4.2.2. Classificador KNN

O classificador KNN é um dos mais usados, mais simples de implementar e que permite obter bons resultados na resolução de problemas de classificação [23]. Para classificar uma amostra de teste, o KNN calcula a distância a que esta se encontra das k amostras mais próximas do conjunto de treino, é analisada a classe de cada k amostra e a classe que tiver mais amostras é a classe atribuída à amostra de teste [24].

Durante a fase de treino, este classificador guarda todo o conjunto de treino, que consiste nas amostras e as suas respetivas classes. Posteriormente, o utilizador define o valor ou gama de valores do parâmetro k para ser estimado. Ao receber uma amostra de teste o classificador vai fazer a comparação entre esta e as k amostras de treino mais próximas, a classe que tiver mais amostras de treino é atribuída à amostra de teste.

¹ *Scikit-learn* é uma biblioteca que contém métodos de aprendizagem automática desenvolvidos em *Python*

A Figura 4-2 exemplifica o procedimento utilizado pelo KNN. Neste exemplo pretende-se a classificação do ponto verde, situado no centro da figura, como pertencente à classe dos triângulos vermelhos ou dos quadrados azuis. O círculo menor, delimitado por uma linha contínua, exemplifica o caso em que o número de vizinhos escolhidos foi de 4, que por ser número par pode levar a resultados ambíguos, como é o caso desta figura, em que existem dois elementos pertencentes a cada uma das classes. Por outro lado, o círculo maior, delimitado por uma linha tracejada, possui um número ímpar de vizinhos, pelo que é possível obter uma classificação do ponto que se pretende classificar.




Figura 4-2: Procedimento utilizado pelo KNN para a classificação (adaptado de [25])

Existem dois parâmetros que têm grande influência no desempenho deste classificador, são eles: o número de vizinhos (k) e a métrica de distâncias. Um valor de k baixo origina maus resultados devido à presença de ruído em algumas amostras. Porém um valor de k elevado, apesar de reduzir o ruído, não permite definir distintamente uma classe de outra. Relativamente às métricas, neste trabalho são usadas a euclidiana e a de *Mahalanobis*.

A distância euclidiana é a métrica mais utilizada para o cálculo da distância entre dois vetores e é calculada através da equação:

$$d_{st}^2 = (x_s - z_t)(x_s - z_t)' \quad (3.3)$$

O vetor x_s e z_t provêm, respetivamente, da matriz do conjunto de treino X , de dimensão $(mx \times d)$, e da matriz do conjunto de teste Z , de dimensão $(mz \times d)$.

Outra métrica usada é a distância de *Mahalanobis* é definida pela equação (3.4), onde C é a matriz de covariância:

$$d_{st}^2 = (x_s - z_t)C^{-1}(x_s - z_t)' \quad (3.4)$$

O KNN básico classifica com pesos uniformes, isto é, a amostra de teste é classificada com base no maior número de vizinhos pertencentes a uma classe. No entanto, em alguns casos a atribuição de um peso inversamente proporcional à distância entre a amostra e os vizinhos, pode

contribuir para a obtenção de melhores classificações. Neste trabalho foram utilizados os pesos uniformes e de distância.

4.2.3. Classificador SVM

A SVM é um dos classificadores mais utilizados em reconhecimento de padrões pois possui uma robusta capacidade de aprendizagem a partir de dados experimentais [26]. A implementação mais simples deste classificador ocorre em problemas com apenas duas classes. A sua implementação parte da escolha, de entre os pontos do conjunto de treino, dos pontos que serão considerados pertencentes aos vetores de suporte. Com base nos vetores de suporte é escolhido o hiperplano que permite maximizar a margem de separação entre os vetores de suporte das classes. A soma da distância do elemento da classe 1 mais próximo do hiperplano com a distância do elemento da classe 2 mais próximo do hiperplano é denominada de margem.

Na Figura 4-3.(a) é possível observar que existem múltiplos hiperplanos que permitem a separação dos dois conjuntos de dados. Se o hiperplano escolhido passar muito próxima de um ou mais dados, vai existir um problema de sensibilidade ao ruído, pelo que o SVM procura o hiperplano que obtém a maior distância mínima do conjunto de dados. Ao dobro desta distância, dá-se o nome de margem, ou seja, o hiperplano ótimo é o que permite maximizar a margem entre as duas classes, como representado na Figura 4-3.(b) [27].




Figura 4-3: (a) Conjunto de dados linearmente separáveis pelo hiperplano
(b) Hiperplano ótimo que maximiza a margem (adaptado de [27])

No caso dos problemas de multiclasse, como é o caso deste trabalho que utiliza quatro classes, a sua resolução consiste na decomposição deste tipo de problemas em múltiplos problemas de classificação binária, pelo que existem duas abordagens na sua decomposição: um contra um ou um contra todos.

Neste trabalho, o classificador usado implementa a opção um contra um. São criados $\frac{K(K-1)}{2}$ classificadores binários, sendo K o número de classes existentes, neste caso 4. Cada classificador recebe do conjunto de treino, as amostras do par de classes que contém, com o intuito de aprender a

distingui-las. Aquando da classificação do conjunto de treino, todos os classificadores são sujeitos a uma amostra e a classe que obtiver um valor mais elevado é considerada a correta [28].

Neste classificador é possível ajustar o parâmetro C que é responsável pelo equilíbrio entre o número de erros e a maximização da margem. Apesar de um valor de C elevado provocar a diminuição dos erros, pode provocar a um decréscimo na capacidade de generalização por parte do classificador [29].

O objetivo do classificador é estimar a função que melhor representa o hiperplano, função esta que é posteriormente usada como regra de decisão para a classificação do conjunto de teste [30]. Muitos problemas de classificação não permitem uma separação linear entre as classes, o que leva à necessidade de se usar funções de *núcleo* não lineares [31]. Para isso recorre-se à transformação do espaço original, que contém o conjunto de treino, num espaço de alta dimensão, utilizando a projeção realizada pela função de *núcleo* não linear, tendo por objetivo encontrar, neste novo espaço, o hiperplano que permita a separação linear das classes [26].

Neste trabalho foram utilizadas duas funções de *núcleo*: linear e gaussiano. A função de *núcleo* linear é apresentada na equação:

$$L(x, y) = x^T y + c \quad (3.5)$$

A função de *núcleo* gaussiano, também denominado de *Radial Basis Function* (RBF), resulta da projeção dos dados de treino no espaço de características, ou de alta dimensão. A estimativa do parâmetro γ é fulcral no desempenho do *núcleo*. Para um valor elevado a função tenderá a ter uma resposta próxima da linearidade, no entanto, um valor reduzido torna a classificação muito sensível ao ruído. A função é definida pela equação:

$$R(x, y) = \exp \left(-\frac{\|x - y\|^2}{2\gamma^2} \right) \quad (3.6)$$

5. Resultados e discussão

Este capítulo apresenta os resultados obtidos pelo algoritmo, desenvolvido em *Python*[™] 2.7, baseado na metodologia anteriormente definida. Realizou-se diversos testes com o intuito de se comparar o desempenho entre os classificadores usados, assim como a análise da influência do número de características no seu desempenho. Para tal foi implementado um seletor de características e foram analisados os desempenhos com e sem a sua utilização.

5.1. Conjunto de dados

As imagens aéreas ortorrectificadas utilizadas neste trabalho foram gentilmente cedidas pelo CIGeoE. Estas representam uma parte da zona militar de Mafra e da zona de Valença, contêm informação na banda do visível, ou seja, contêm as três bandas, vermelho, verde e azul (RGB). A dimensão das imagens é variável, porém a resolução espacial é a mesma; cada píxel representa 80 centímetros no terreno.

Inicialmente o objetivo seria a classificação das oito classes, descritas no capítulo 3, utilizadas pelo CIGeoE, porém seguindo a metodologia adotada e explicada no capítulo anterior, não foi possível obter resultados satisfatórios com todas estas classes. As classificações aproximavam-se da aleatoriedade, algumas classes apresentavam um desempenho inferior a 20%. Concluiu-se que algumas classes apresentavam semelhanças que não permitiam a sua distinção, causando assim ruído e não permitindo a sua correta classificação. Perante estes problemas, a solução adotada passou pela fusão de algumas classes com fortes similaridades e alteração de outras, com o intuito de reduzir os erros por estas introduzidos e assim ser possível desenvolver um algoritmo capaz de realizar a classificação de umas classes mais genéricas, contudo bastante distintas entre si.

De seguida são demonstradas as alterações adotadas, que permitiram a redução das oito classes, inicialmente definidas, para as quatro classes utilizadas na parte prática desta dissertação. É referido as denominações destas novas quatro classes, assim como o que estas representam.

As classes “Arvoredo denso” e “Mato denso” apresentam uma elevada densidade de vegetação e a cor predominante é o verde, pela que estas classes sofreram uma fusão e deram origem à classe “Vegetação densa” que representa todas as áreas cuja densidade de vegetação não permite a observação do solo através das imagens aéreas. A Figura 5-1 esquematiza a fusão descrita.




Figura 5-1: Fusão da classe “Arvoredo denso” (a) com a classe “Mato denso” (b) resulta na classe “Vegetação densa” (c)

Na Figura 5-2 está representada a fusão das classes “Arvoredo esparsa” e “Mata” que deram origem à classe “Vegetação Esparsa”, onde mais uma vez o nome escolhido permite associar diretamente ao que esta representa, isto é, as áreas em que a vegetação se encontra dispersa.




Figura 5-2: Fusão da classe “Arvoredo esparsa” (a) com a classe “Mata” (b) resulta na classe “Vegetação esparsa” (c)

A terceira fusão é essencialmente uma alteração de nome, uma vez que apenas abrange uma das oito classes definidas, a classe “Clareira”. A classe criada que a sucede é a classe “Vegetação escassa”, esta mudança de nome não visa apenas esta classe específica, mas sim todas as áreas em que a vegetação existente é pouca ou nenhuma, daí a origem da palavra escassa. Exemplos desta nova classe são as zonas de pasto, zonas que sofreram um corte de árvores ou onde ocorreu um incêndio, etc. A Figura 5-3 representa esta alteração de nomenclatura.



Figura 5-3: Alteração da classe “Clareira” (a) para a classe “Vegetação escassa” (b)

O intuito da criação destas três novas classes é o relacionamento entre o adjetivo utilizado em cada uma e a densidade de vegetação que estas representam, isto permite que as mesmas tenham características a nível de densidade bastante díspares entre si, o que viabiliza a sua adoção na implementação do algoritmo desenvolvido.

Por último é feita uma outra fusão, que depreende as classes referentes às zonas de cultivo, são elas “Pomar”, “Vinha” e “Pomar/Vinha”. Uma das razões que originou a fusão destas classes, para além das suas semelhanças, é as imagens fornecidas serem de uma zona onde predominam os minifúndios, zona de Valença, pelo que as áreas pertencentes exclusivamente ou à classe “Pomar” ou à classe “Vinha” têm dimensões tão pequenas que na realidade são pertencentes à classe “Pomar/Vinha” que já representa a junção destas classes. Com base nisto, a fusão resultou numa “eliminação” das outras classes, resultando apenas a classe “Pomar/Vinha”, representando esta todas as zonas que contenham áreas de pomar e/ou de vinha. Na Figura 5-4 está representado este processo.




Figura 5-4: Fusão das classes “Pomar” (a), “Vinha” (b) e “Pomar/Vinha” (c) que resulta na classe “Pomar/Vinha” (d)

5.2. Análise do tipo de vegetação

Com o intuito de se classificar o tipo de vegetação, foi feita uma análise das imagens e definiram-se quatro classes para representar essas densidades, são elas: vegetação densa, vegetação esparsa, vegetação escassa e pomar/vinha. A vegetação densa representa zonas em que existe uma grande quantidade de árvores ou mato que não permite a visualização do solo. A vegetação esparsa contém árvores e/ou arbustos dispersos, pelo que é possível observar pequenas zonas de solo. A vegetação escassa abrange todas as zonas que contêm vegetação de dimensões irrelevantes ou impercetíveis. A última classe, pomar/vinha, representa as zonas de cultivo de árvores de fruto, habitualmente caracterizadas por zonas de árvores muito bem definidas.

Utilizou-se as seis imagens, referidas na Tabela 5-1, como imagens de teste. Destas resultam 2338 ROI com tamanho de 20 píxeis por 20 píxeis cada.

Tabela 5-1: Caraterísticas das imagens originais

Imagem	Dimensão em nº de píxeis
A	400 x 400
B	300 x 200
C	300 x 400
D	180 x 140
E	500 x 500
F	400 x 400
G	400 x 400

Em cada classificador procedeu-se à comparação das precisões globais destes, neste trabalho denominada de *Overall Accuracy* (OA) e expressa em percentagem. Estas podem apresentar variações dependendo da implementação usada, duas métricas, no caso do KNN, e de dois *núcleos*, no caso do SVM. É também analisada a influência do número de características usadas no desempenho dos classificadores. Para tal foi implementado um seletor de características, que de entre as 86 características calculadas, recursivamente seleciona entre 5 a 40 características, utilizando incrementos de 5, sendo as características escolhidas, as que contêm informação mais relevante para a distinção das quatro classes. A utilização de mais de 40 características induz a um decréscimo na precisão global do classificador, razão pela qual este foi o valor máximo escolhido na implementação do seletor.


5.2.1. Caracterização do conjunto de treino

Com o intuito de se construir um conjunto de treino que permite uma correta aprendizagem dos classificadores implementados e consequente classificação das imagens de teste fornecidas, foram recolhidas 4 imagens representativas de cada classe, perfazendo um total de 16 imagens de treino, todas com um tamanho fixo de 100 píxeis por 100 píxeis. Contêm a mesma resolução espacial das imagens cedidas pelo CIGeoE, 80 centímetros.


Posteriormente estas imagens são divididas em ROIs com uma dimensão de 20 píxeis por 20 píxeis. Em cada ROI são calculadas as características descritas na secção 4.1, a partir dos valores de intensidade dos píxeis. Cada imagem produz 25 ROIs, perfazendo um total de 100 amostras por cada classe e consequente vetor de treino, que contém as quatro classes, de dimensão 400x86.

Na Figura 5-5 são apresentadas as imagens utilizados no conjunto de treino para representar as quatro classes: vegetação densa, vegetação esparsa, vegetação escassa e pomar/vinha.

Vegetação densa:



Vegetação esparsa:



Vegetação escassa:



Pomar/Vinha:




Figura 5-5: Imagens representativas de cada classe utilizadas no conjunto de treino

Depois de constituído o conjunto de treino, e para que fosse possível criar conjuntos de treino com um número de características variável, neste caso valores entre as 5 e as 40 características, foi implementada uma técnica de seleção de características denominada de *Back Feature Selection* (BFS) [32]. Esta técnica consiste na eliminação recursiva das características cuja informação não é relevante para a distinção entre classes, o processo é iniciado com todas as características e termina quando é obtido o número de características estabelecido.

5.2.2. Caracterização do conjunto de teste

Com o objetivo de se realizar uma comparação entre os classificadores implementados tem que se definir um conjunto de teste. Neste trabalho foram utilizadas seis imagens como conjunto de teste, das quais resultam 2338 ROIs analisadas. As imagens diferem entre si, relativamente, ao tamanho, tipo de vegetação e distribuição de vegetação. O desempenho dos classificadores é comparado através do cálculo da OA.

As imagens usadas foram classificadas manualmente, sendo esta considerada a classificação de referência. A Figura 5-6 apresenta a legenda associada às imagens que serão apresentadas neste capítulo.




Figura 5-6: Legenda

A primeira imagem testada é designada por Imagem A e é apresentada na Figura 5-7. Tem um tamanho de 400 píxeis por 400 píxeis e contém as classes vegetação densa, vegetação esparsa e vegetação escassa. Esta imagem foi escolhida devido à presença de três classes, sendo que duas delas representam 86,5% da área da imagem, a terceira classe, vegetação esparsa, representa as zonas de transição entre as outras classes, assim como as zonas de árvores e arbustos dispersos.




Figura 5-7: Representação da Imagem A (a) e respectiva classificação manual (referência) (b)

A segunda imagem tem um tamanho de 300 píxeis por 200 píxeis e contém apenas duas das classes, vegetação escassa e vegetação esparsa. Nesta imagem a classe vegetação esparsa é composta por árvores e arbustos, assim como, pela presença de uma estrada, que neste caso estabelece a separação entre as duas classes. A Figura 5-8 apresenta a imagem B e a sua respectiva classificação de referência.




Figura 5-8: Representação da Imagem B (a) e respectiva classificação manual (referência) (b)

A terceira imagem, representada na Figura 5-9, tem um tamanho de 300 píxeis por 400 píxeis e foi escolhida por apresentar uma área de vegetação esparsa diferente da existente na imagem A.




Figura 5-9: Representação da Imagem C (a) e respectiva classificação manual (referência) (b)

Na Figura 5-10 é representada a imagem D com um tamanho de 180 píxeis por 140 píxeis e assim como a imagem B só contém as classes vegetação esparsa e vegetação escassa, mas a vegetação esparsa é diferente da anterior, é constituída essencialmente por árvores, sendo bastante perceptível que ROI pertence a que classe.




Figura 5-10: Representação da Imagem D (a) e respetiva classificação manual (referência) (b)

A quinta imagem, Figura 5-11, cujo tamanho é de 500 píxeis por 500 píxeis, contém uma grande área de pomares e vinhas. Esta área é atravessada por uma estrada, esta foi classificada como vegetação esparsa uma vez que as ROIs que a contêm também possuem partes de árvores, pertencentes à classe pomar/vinha.




Figura 5-11: Representação da Imagem E (a) e respetiva classificação manual (referência) (b)

A penúltima imagem de teste, representada na Figura 5-12, contém maioritariamente vegetação densa e vinhas. Volta a estar presença uma estrada que serve de fronteira entre estas duas classes, no caso desta imagem as dimensões da estrada produzem características que se assemelham a zonas sem vegetação, razão pela qual esta zona é classifica como vegetação escassa. Tem um tamanho de 400 píxeis por 400 píxeis.




Figura 5-12: Representação da Imagem F (a) e respetiva classificação manual (referência) (b)

A última imagem de teste, é semelhante à anterior, no entanto a tonalidade das classes é diferente, razão pela qual foi escolhida. Como é facilmente observável, existe novamente uma zona de transição constituída por uma estrada, mas desta vez contendo características associadas tanto à classe de vegetação escassa como à de vegetação esparsa. Tem um tamanho de 400 píxeis por 400 píxeis e é representada pela Figura 5-13




Figura 5-13: Representação da Imagem E (a) e respetiva classificação manual (referência) (b)

5.2.3. Classificador KNN

As imagens de teste foram classificadas utilizando o classificador KNN, no qual foi analisada a influência da métrica utilizada no cálculo das distâncias entre a amostra de teste e os k vizinhos mais próximos pertencentes ao conjunto de treino.

Foram testadas as métricas de distância euclidiana e distância de *mahalanobis*. O parâmetro k , que representa o número de vizinhos, foi obtido através da técnica *GridSearchCV*, com o intuito de se obter os melhores resultados possíveis. O número de características utilizadas foi alterado iterativamente, sendo registrado a OA obtida em cada iteração. O valor de k não deve ser baixo, uma vez que torna a classificação sensível a pontos de ruído, porém também não deve ser muito elevado, pois conduz a uma maior probabilidade de incluir incorretamente elementos de outras classes vizinhas [24]. Neste trabalho o valor médio de k obtido foi de 4.

Na Figura 5-14 são apresentados os resultados médios obtidos das seis imagens de teste com o classificador KNN.




Figura 5-14: Resultados obtidos com o classificador KNN

Por inspeção do gráfico conclui-se que os melhores valores de OA são obtidos quando são utilizadas as 10 características mais relevantes, 6 delas são respectivamente a média e a mediana para cada uma das bandas, ou seja, são as características de primeira ordem que permitem uma melhor distinção entre as diferentes classes, resultando num valor de OA mais elevado. Verifica-se a semelhança nos resultados entre as métricas de cálculo da distância. A métrica *mahalanobis* apresenta o melhor resultado, com um valor de OA de 88,3% para um valor médio de k de 5 e utilizando 10 características.

Foi testada a influência do seletor de características. Para tal, executou-se o classificador com as 86 características do conjunto de treino. Com os resultados, verificou-se que o desempenho do classificador aumenta em 9,25% com a utilização do seletor de características. Este aumento já seria de esperar uma vez que o seletor permite a eliminação das características que contêm menor informação, ficando apenas aquelas que permitem obter uma melhor classificação das classes presentes em cada imagem. Os resultados obtidos estão representados na Tabela 5-2

Tabela 5-2: Impacto da utilização do seletor de características no desempenho da classificador KNN

Sem seletor	Com Seletor		Métrica	Aumento do desempenho (%)
OA (%)	Nº de características	OA (%)		
79	10	88,3	<i>Mahalanobis</i>	9,3
79	10	88,2	Euclidiana	9,2
			Valor médio	9,25

5.2.4. Classificador SVM

O classificador SVM permite a implementação de várias funções de *núcleo*. Neste trabalho foram utilizadas as funções de *núcleo* linear e RBF. É possível também ajustar o parâmetro C que é responsável pelo equilíbrio entre o número de erros e a maximização da margem. O *núcleo* RBF têm ainda a possibilidade de maximizar os resultados de classificação através do ajuste do parâmetro σ .

No ajuste do parâmetro C foi testada uma gama de valores de 0.1 até 1000 e o parâmetro σ sofreu uma variação de 0.1 até 100. Recorre-se novamente à técnica *GridSearchCV* para a parametrização de C e σ . O conjunto de teste foi classificado com os parâmetros estimados com a técnica *10-fold cross validation*. Os resultados médios obtidos com o classificador SVM com os dois *núcleos*, são apresentados na Figura 5-15.




Figura 5-15: Resultados obtidos com o classificador SVM

Através da análise do gráfico é possível observar que em ambos os *núcleos* existe um aumento significativo da OA até às 20 características, sendo que após este valor os *núcleos* têm um comportamento contrário. A diferença entre os dois, no melhor caso é de 0,9% para 25 características e no pior caso é de 10,5% para 40 características. É com 20 características que se obtém o melhor valor de OA para este classificador, utilizando-se o *núcleo* RBF com os parâmetros $C = 10$ e $\sigma = 10^{-4}$.

Dessas 20 características, 12 delas pertencem à energia calculada através das GLCM, o que significa as imagens apresentam zonas uniformes, isto é, zonas que pertencem à mesma classe.

Para este classificador também foi testada a influência do seletor de características, com o qual se verificou um aumento de 7,25% no desempenho do classificador, como se pode observar pelos resultados apresentados na Tabela 5-3. No caso do *núcleo* RBF, para além das 20 características já referidas, também são selecionadas as que dizem respeito à homogeneidade, mediana e desvio padrão, a predominância é à mesma sobre as características de segunda ordem, mas já inclui a influência de algumas características de primeira ordem.

Tabela 5-3: Impacto da utilização do seletor de características no SVM

Sem seletor OA (%)	Com Seletor		Núcleo	Aumento do desempenho (%)
	N° de características	OA (%)		
81,6	20	89,8	RBF	8,2
82,7	40	89	Linear	6,3
Valor médio				7,25

5.2.5. Comparação dos resultados para as imagens de teste


Com o intuito de se estabelecer uma comparação entre os melhores resultados obtidos pelos classificadores (provenientes da estimativa dos parâmetros através da técnica *GridSearchCV*), cada imagem de teste foi reconstruída com base na classificação atribuída pelos classificadores.

A Tabela 5-4 apresenta uma comparação entre o melhor resultado de cada classificador para a imagem A. Os dois classificadores apresentam um desempenho muito semelhante.


A Figura 5-16 mostra as imagens artificiais criadas com esses resultados.

Tabela 5-4: Comparação dos melhores resultados para a imagem A


Classificador	OA (%)	Nº de características
KNN	91,3	10
SVM	92,5	30




(a)



(b)



(c)



(d)


Figura 5-16: (a) Imagem A; (b) classificação de referência; (c) classificação obtida com o KNN; (d) classificação obtida com o SVM

Através da interpretação visual das imagens obtidas é possível concluir que ambos os classificadores apresentam uma elevada precisão na classificação da classe vegetação densa, porém o mesmo não é verdade para as classes vegetação esparsa e vegetação escassa. No entanto a comparação está a ser efetuada com uma imagem que foi classificada manualmente, podendo esta não ser a melhor classificação possível para a imagem. O classificador KNN utiliza 10 características, 7 das quais são de primeira ordem, por outro lado o classificador SVM recorre a 30 características, sendo utilizadas maioritariamente características de segunda ordem.


A Tabela 5-5 contém os melhores resultados, e a Figura 5-17 mostra as imagens artificiais criadas com esses resultados da imagem B. Neste caso, pretendia-se a classificação entre as classes vegetação esparsa e vegetação escassa, sendo que a primeira está situada na diagonal inferior da imagem e a segunda na diagonal superior. O número de características usadas volta a ser o mesmo para ambos os classificadores.

Tabela 5-5: Comparação dos melhores resultados para a imagem B


Classificador	OA (%)	Nº de características
KNN	91,3	10
SVM	94	30




(a)



(b)



(c)




(d)

Figura 5-17: (a) Imagem B; (b) classificação de referência;
(c) classificação obtida com o KNN; (d) classificação obtida com o SVM


Os dois classificadores produzem uma imagem artificial semelhante à classificação de referência. A Tabela 5-6 contém os melhores resultados, e a Figura 5-18 mostra as imagens artificiais criadas com esses resultados da imagem C. Nesta imagem os resultados obtidos são inferiores em relação aos obtidos nas imagens A e B, os erros ocorrem essencialmente na classificação das zonas de sombra presentes nesta imagem. Estas zonas foram classificadas manualmente como pertencentes à classe vegetação esparsa, enquanto que os classificadores as classificaram como vegetação densa, mais uma vez, isto poderá ser um erro da classificação manual e não dos classificadores. O KNN permanece com as 10 características já referidas nas outras imagens, por outro lado, o SVM desta vez utiliza apenas 15 características, 12 delas pertencentes à característica energia extraída das GLCM, as características de segunda ordem voltam a ser as mais relevantes para a classificação das imagens através do SVM.

Tabela 5-6: Comparação dos melhores resultados para a imagem C

Classificador	OA (%)	Nº de características
KNN	84,3	10
SVM	84,7	15



(a)



(b)




Figura 5-18: (a) Imagem C; (b) classificação de referência;
(c) classificação obtida com o KNN; (d) classificação obtida com o SVM

A quarta imagem utilizada, D, é uma área maioritariamente ocupada por vegetação esparsa do tipo árvore e por uma área com vegetação escassa. A Tabela 5-7 e a Figura 5-19 demonstram, respetivamente, os melhores resultados e as imagens obtidos através desses mesmos resultados.

Como é possível observar, neste caso, o classificador SVM obtém uma classificação quase perfeita, apenas classificou incorretamente uma das ROI. Como seria espectável, a energia é, mais uma vez, uma das características que contém mais informação para a distinção entre classes, isto porque imagem consiste em duas áreas bastante uniformes, uma com vegetação esparsa e outra com vegetação escassa. O classificador KNN também faz uso de 20 características para obter o melhor resultado, 8 delas pertencentes às de primeira ordem, média, mediana e valor máximo de intensidade e as restantes pertencentes às de segunda ordem, segundo momento angular e homogeneidade. Porém, o KNN produz mais erros que o SVM, erros esses que pertencem às ROI que foram classificadas como pertencentes à classe vegetação esparsa, mas que foram classificadas como vegetação escassa. Todas as ROIs incorretamente classificadas possuem pelo menos 50% da sua área com vegetação escassa, o que poderá ser a causa para a incorreta classificação por parte do KNN.

Tabela 5-7: Comparação dos melhores resultados para a imagem D

Classificador	OA (%)	Nº de características
KNN	88,9	20
SVM	98,4	20





Figura 5-19: (a) Imagem D; (b) classificação de referência;
 (c) classificação obtida com o KNN; (d) classificação obtida com o SVM


De seguida são apresentados na Tabela 5-8 e na Figura 5-20, os valores dos resultados e as imagens criadas, respetivamente.

Tabela 5-8: Comparação dos melhores resultados para a imagem E


Classificador	OA (%)	Nº de características
KNN	94,6	10
SVM	94,6	35




(a)



(b)



(c)



(d)

Figura 5-20: (a) Imagem E; (b) classificação de referência;
(c) classificação obtida com o KNN; (d) classificação obtida com o SVM

Esta imagem difere bastante das anteriores, uma vez que representa uma grande área de pomar e/ou vinha, existindo apenas uma estrada que atravessa sensivelmente metade da imagem. A zona com a estrada foi classificada de vegetação esparsa, uma vez que as ROIs que a contêm também possuem partes de árvores, pertencentes à classe pomar/vinha. Apesar de os classificadores terem obtidos resultados próximos dos 95%, não significa que tenha existido uma correta classificação. Como é possível observar, a estrada é incorretamente classificada, isto vai contra os resultados obtidos, no entanto a OA é a relação entre o número de ROIs corretamente classificadas e o número total de ROIs, e neste caso a estrada apenas contém 35 das 625 ROIs pertencentes à imagem.

A Tabela 5-9 apresenta uma comparação entre o melhor resultado de cada classificador para a imagem F. A Figura 5-21 mostra as imagens artificiais criadas com esses resultados. Os dois classificadores apresentam um desempenho muito semelhante.

Tabela 5-9: Comparação dos melhores resultados para a imagem F

Classificador	OA (%)	Nº de características
KNN	93,8	10
SVM	92,8	30





Figura 5-21: (a) Imagem F; (b) classificação de referência; (c) classificação obtida com o KNN; (d) classificação obtida com o SVM

Na Figura 5-21 é possível constatar que os dois classificadores produzem bons resultados na classificação das duas maiores áreas existentes na imagem F, uma pertencente à classe vegetação densa e a outra pertencente à classe pomar/vinha. Os maiores erros ocorrem na classificação da zona de transição, caracterizada pela existência de uma estrada, sendo que neste caso, as suas dimensões fazem com que esta contenha características que se assemelham à ausência de vegetação. Razão pela qual esta zona de transição foi manualmente classificada como pertencente à classe vegetação escassa.


Na Tabela 5-10 são apresentados resultados obtidos para a última imagem do conjunto de teste e na Figura 5-22 são exibidas as imagens criadas com base nos resultados. Esta imagem à semelhança da anterior possui duas grandes áreas pertencentes às classes vegetação densa e pomar/vinha. Neste caso, a área da classe pomar/vinha é caracterizada por uma tonalidade diferente da presente na imagem anterior. A zona de transição, novamente associada a uma estrada, é classificada tanto como pertencente à classe vegetação esparsa como à classe vegetação escassa, dependendo das suas características nas ROIs estabelecidas.

Tabela 5-10: Comparação dos melhores resultados para a imagem G

Classificador	OA (%)	Nº de características
KNN	88,3	10
SVM	93,8	20



(a)



(b)




Figura 5-22: (a) Imagem G; (b) classificação de referência;
(c) classificação obtida com o KNN; (d) classificação obtida com o SVM

Com base na Figura 5-22, observa-se que o classificador KNN apresenta grande parte dos seus erros na classificação da vegetação de densa, assim como na zona de transição. Como ocorreu nas outras imagens, as características usadas são as de primeira ordem, o que poderá indicar que nesta imagem estas não sejam as mais indicadas.

O classificador SVM por outro lado, apresenta bons resultados nas duas maiores áreas, contendo os seus erros essencialmente na zona de transição. As características mais relevantes voltam a ser as associadas à textura, características de segunda ordem, não se revelando tão eficazes na distinção entre as classes vegetação esparsa e vegetação escassa.

5.2.6. Comparação de classificadores

Uma vez efetuados os testes com os classificadores para cada imagem de teste, procedeu-se ao cálculo dos valores médios da OA de cada classificador com o intuito de ser possível comparar o comportamento destes.

O Figura 5-23 permite observar o comportamento dos classificadores em função das características, os valores foram calculados através do resultado médio obtido por cada classificador, com a parametrização da técnica *GridSearchCV*.




Figura 5-23: Resultados médios dos classificadores

Observa-se que o desempenho dos classificadores é contrário quando o número de características é inferior a 20 características, o que poderá dever-se ao facto de as características, seleccionadas até este valor, serem as de primeira ordem. Como observado nos resultados obtidos para cada imagem de teste, estas características são as que permitem obter os melhores resultados. Cerca de 88% com o classificador KNN para 10 características, sendo que estes resultados diminuem aquando da introdução das características de segunda ordem, atingindo os 75% para 40 características.

No caso do classificador SVM, existe um aumento de cerca de 27% da OA entre as 5 e as 20 características, sendo que o maior crescimento ocorre na transição das 10 para as 15 características, cerca de 15%, devido à introdução das características de segunda ordem. Após as 20 características, onde o SVM obtém cerca de 90%, este acompanha o decréscimo de desempenho observado no KNN e atinge um valor de OA de 78,5% para 40 características.

As melhores classificações ocorrem com o classificador SVM utilizando a função de *núcleo* RBF e com um número de características igual a 20.

5.3. Recursos computacionais e tempo de processamento

Nesta secção são descritas as especificações técnicas do equipamento que foi utilizado para a produção e obtenção dos resultados referidos neste capítulo. Os classificadores são comparados relativamente ao consumo de tempo de processamento.

Na secção 5.2, os resultados apresentados foram obtidos através da utilização de um computador com processador *Intel Core i7 @ 2,3GHz*, 16 GB de memória de acesso aleatório (RAM) e sistema operativo *Mac OS X 10.10.4*. Para a implementação das funções e desenvolvimentos dos algoritmos procedeu-se à utilização do software de programação *Spyder™*, que consiste num ambiente de desenvolvimento científico em *Python™ 2.7*.

Os resultados da precisão global dos classificadores são importantes, no entanto também é relevante analisar o tempo que os classificadores necessitam para classificar uma amostra de teste. Sendo este um aspeto importante na escolha do classificador, uma vez que, um classificador pode ter uma precisão global superior a outro, mas necessitar de uma quantidade de tempo muito superior ao outro, o que inviabiliza a sua utilização.

De forma a ser possível a comparação dos tempos de processamento entre os classificadores implementados, analisaram-se todas as imagens de teste, tendo em conta um conjunto de treino com 20 características. A Figura 5-24 apresenta os tempos de processamentos obtidos para a classificação de cada uma das sete imagens de teste utilizadas.




Figura 5-24: Tempo de processamento, em segundos, necessário para classificar cada imagem de teste

Através da análise do gráfico, é possível observar que os tempos de processamento de classificação obtidos pelo classificador SVM são inferiores aos obtidos pelo classificador KNN em todas as imagens de teste, sendo que o SVM é, em média, cerca de 30% mais rápido a executar comparativamente com o KNN.

Tabela 5-11: O.A. obtida pelos classificadores utilizando 20 características

Imagem	O.A. (%)	
	KNN	SVM
A	76,8	88,5
B	82,0	81,3
C	67,7	86,3
D	85,7	98,4
E	91,8	92,0
F	73,0	93,0
G	61,0	90,5
Média	76,9	90,0

6. Conclusões

Nesta tese desenvolveu-se um algoritmo para a discriminação do coberto vegetal baseado em aprendizagem automática, tendo em visto o estudo e compreensão de alguns dos algoritmos já desenvolvidos pela comunidade científica. No CIGeoE, a discriminação do coberto vegetal é feita manualmente, por equipas de fotogrametristas especializados, através da extração da informação proveniente de fotografias aéreas ortorrectificadas. Uma vez que este processo é feito manualmente é possível constatar dois principais problemas, o primeiro é o tempo despendido para a elaboração do mesmo e o outro é que a informação extraída por um indivíduo nunca é exatamente igual à extraída por outro. Foi com base nestes problemas encontrados que se propôs o desenvolvimento de uma metodologia que, de forma automática ou semiautomática, extraia informação das fotografias aéreas e utilize métodos de classificação, permitindo assim a discriminação dos diferentes tipos de vegetação utilizados pelo CIGeoE. O desenvolvimento desta metodologia consiste assim no principal objetivo desta dissertação de mestrado.

Com vista a atingir o objetivo proposto adotou-se uma metodologia de trabalho composta por três etapas essenciais: extração de características, seleção de características e classificação das imagens. O CIGeoE forneceu fotografias aéreas ortorrectificadas das zonas de Valença e Mafra, assim como as oito classes por eles usadas na discriminação do coberto vegetal. Nestas fotografias foram extraídas regiões de interesse que permitam representar cada uma destas classes. Estas foram divididas em regiões de menor dimensão e foram extraídas as características de primeira e segunda ordem constituindo-se assim o conjunto de treino usado para ensinar os classificadores. De seguida foi implementado o algoritmo de seleção de características BFS, que recursivamente elimina aquelas que são redundantes e/ou fortemente correlacionadas entre si, permitindo a seleção das características que contêm a informação mais relevante para a discriminação das diferentes classes. Com o conjunto de treino e respetivas características mais relevantes, é aplicado o método *GridSearchCV*, este permite a obtenção dos parâmetros de entrada dos classificadores KNN e SVM através de uma busca exaustiva entre todos os parâmetros atribuídos, sendo que esta busca é otimizada pelo uso da técnica *Validação cruzada K-fold*. A utilização desta técnica conduz a uma diminuição do erro de classificação. Estimados os parâmetros de entrada dos classificadores, é-lhes submetida cada uma das oito imagens de teste selecionadas para estes procederem à sua classificação. As imagens de teste à semelhança das imagens de treino, são divididas em ROIs com uma dimensão de 20 píxeis por 20 píxeis, cada ROI é classificada como pertencente a uma das classes definidas.

Com base na metodologia acima referida procedeu-se à obtenção dos resultados. Contudo a utilização das oito classes definidas pelo CIGeoE não permitiu a obtenção de resultados satisfatórios, as classificações aproximavam-se da aleatoriedade, algumas classes apresentavam um desempenho inferior a 20%. Concluiu-se que a principal causa destes fracos desempenhos era a similaridade entre algumas classes, razão pela qual se optou pela fusão de classes para reduzir este efeito. As oito classes deram origem a quatro novas classes, mais genéricas, mas bem distintas entre si. As três primeiras classes distinguem-se pela densidade de vegetação que representam, enquanto que a

quarta se destaca por representar as zonas de cultivo, como os pomares e vinhas. Com estas novas classes é constituído um novo conjunto de treino e de teste. Procedeu-se à extração e seleção de características, assim como parametrização dos classificadores. De seguida, é classificada cada imagem do conjunto de teste com os classificadores KNN e SVM. Ambos apresentam desempenhos médios entre os 62% e os 90%. No caso do KNN conclui-se que este obtém os melhores resultados quando são selecionadas 10 características, sendo estas essencialmente compostas por características de primeira ordem. Significa que, para este classificador as características de segunda ordem, associadas à textura das ROIs apenas vêm introduzir erros na decisão da classe a que cada ROI pertence. Por outro lado, no caso do SVM observa-se o efeito contrário, os melhores resultados são obtidos com a utilização de 20 características, onde já estão presentes características relacionadas com a textura, mais concretamente as características associadas à uniformidade e homogeneidade das ROIs. Conclui-se, portanto, que são estas características que permitem a otimização do desempenho deste classificador. Em ambos os classificadores, observou-se uma diminuição do desempenho dos mesmos com o uso de mais características. De seguida testou-se a influência do seletor de características em ambos os classificadores, pelo que se concluiu que a utilização deste método conduz a um aumento médio de desempenho de 9,25%, no caso do KNN, e de 7,25% no SVM. Estes resultados já seriam espectáveis, uma vez que, o seletor de características apenas seleciona as características que contêm informação mais relevante para a distinção das diferentes classes.

6.1. Trabalho futuro

Os principais objetivos desta dissertação não foram alcançados uma vez que o objetivo era a implementação de um algoritmo que permitisse a correta distinção e classificação entre as oito classes definidas pelo CIGeoE, no entanto os resultados obtidos não foram satisfatórios pelo que foi necessário reformular o problema, procedendo-se à fusão de classes, o que resultou nas quatro classes usadas. Uma das causas para o insucesso nos resultados para as oito classes poderá ter sido as características definidas, podendo não ser estas as mais indicadas para a distinção entre as classes que contêm similaridades.

Como trabalho futuro, seria interessante proceder-se à implementação de uma segmentação antes de se proceder à extração das características, desta forma os diferentes tipos de vegetação estariam delimitados pelas suas fronteiras. Após a segmentação, em cada uma das regiões segmentadas, seria realizada a extração e classificação das amostras do conjunto de teste. Esta segmentação também poderia auxiliar na implementação de classes mais específicas, como, por exemplo, a distinção entre uma zona de pomar e uma zona de vinha, podendo assim ser possível a distinção das oito classes inicialmente definidas.

Outra solução poderia passar pela utilização de imagens com resoluções múltiplas, onde seria inicialmente efetuada a classificação entre as quatro classes utilizadas, mas posteriormente cada uma destas classes era subdividida nas classes originais e que levaram à sua fusão. Um exemplo, seria dentro da classe Vegetação densa, ser separada nas classes Arvoredo denso e Mato denso através da detecção do tipo de vegetação, neste caso, árvore ou arbusto.

Referências

- [1] U. Bradter, T. J. Thom, J. D. Altringham, W. E. Kunin, and T. G. Benton, "Prediction of national vegetation classification communities in the british uplands using environmental data at multiple spatial scales, aerial images and the classifier random forest.(report)," *Journal of Applied Ecology*, vol. 48, no. 4, p. 1057, 2011.
- [2] D. Lewis, S. Phinn, and L. Arroyo, "Cost-effectiveness of seven approaches to map vegetation communities — a case study from northern australia's tropical savannas," *Remote Sensing*, vol. 5, no. 1, pp. 377-414, 2013.
- [3] Nathalie Long, Arnaud Bellec, Erwan Bocher, Gwendall Petit, "Influence of the methodology (pixel-based vs object-based) to extract urban vegetation from VHR images in different urban zones," *5th Geobia Conference*, 2014.
- [4] A. Laliberte, D. Browning, J. Herrick, and P. Gronemeyer, "Hierarchical object-based classification of ultra-high-resolution digital mapping camera (dmc) imagery for rangeland mapping and assessment," *Journal of Spatial Science*, vol. 55, no. 1, pp. 101-115, 2010.
- [5] Z. L. Zhengrong Li, Y. L. Yuee Liu, R. Hayward, R. Walker, "Color and texture feature fusion using kernel pca with application to object-based vegetation species classification," *IEEE 17th International Conference on Image Processing*, pp. 2701-2704, 2010.
- [6] D. S. Chapman, A. Bonn, W. E. Kunin, and S. J. Cornell, "Random forest characterization of upland vegetation and management burning from aerial imagery," *Journal of Biogeography*, vol. 37, no. 1, pp. 37-46, 2010.
- [7] Soe W. Myint, Patricia Gober, Anthony Brazel, Susanne Grossman-Clarke, Qihao Weng, "Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery," *Remote Sensing of Environment*, vol. 115, no. 5, pp. 1145-1161, May 2011.
- [8] Minh Kim, Timothy A. Warner, Marguerite Madden, Douglas S. Atkinson, "Multi-scale GEOBIA with very high spatial resolution digital aerial imagery: scale, texture and image objects," *International Journal of Remote Sensing*, vol. 32, no. 10, pp. 2825-2850, Maio 2011.
- [9] Raquel Soeiro de Brito, *Portugal Perfil Geográfico*. Portugal: Editorial Estampa, 2008.
- [10] Marco Santos. professormarcosantos. [Online].
<http://professormarcosantos.comunidades.net/portugal-seculo-xiii-aspectos-fisicos>
- [11] PEFC. (2013, Janeiro) PEFC Portugal. [Online].
<http://www.pefc.pt/certificacao-gfs/introducao/floresta-portuguesa>
- [12] OverNature. (2015, Setembro) OverNature. [Online].
<http://overnature.com/pt/photo/663-pinhhal.html>
- [13] Rádio Renascença. (2012, Julho) Renascença. [Online].
http://rr.sapo.pt/rubricas_detalhe.aspx?fid=39&did=68454
- [14] Nuno Leitão. (2013, Agosto) Naturlink. [Online].
<http://naturlink.sapo.pt/Natureza-e-Ambiente/Agricultura-e-Floresta/content/Clareiras-nas-florestas->

e-arvores-nas-zonas-abertas?bl=1

- [15] ForWallpaper. (2013) ForWallpaper. [Online]
<http://pt.forwallpaper.com/wallpaper/a-clearing-in-the-forest-545947.html>
- [16] Copa. (2012) Copa. [Online]. <http://www.copa.pt/index.php/field/pomares>
- [17] António Falcão. (2014, Novembro) Revista de Vinhos. [Online].
<http://www.revistadevinhos.pt/artigos/show.aspx?seccao=reportagens&artigo=15459&title=portugal-e-o-mundo-os-numeros-do-vinho-e-da-vinha&idioma=pt>
- [18] Cacilda Basto. (2012, Outubro) SlideShare. [Online].
http://pt.slideshare.net/Cacilda_1/o-mundo-rural-em-portugal-14562566
- [19] CLUVIPOR. (2014, Setembro) Clube de Vinhos Portugueses. [Online].
<https://clubevinhosportugueses.wordpress.com/2014/09/28/doc-douro-cultura-da-vinha-2/>
- [20] M. Arebey, M. Hannan, R. Begum, and H. Basri, "Solid waste bin level detection using gray level co-occurrence matrix feature extraction approach," *Journal of Environmental Management*, vol. 104, pp. 9-18, 2012. [Online].
<http://www.sciencedirect.com/science/article/pii/S0301479712001545>
- [21] Guyon, I., & Elisseeff, A., "An introduction to variable and feature selection," *The Journal of Machine Learning Research*, pp. 1157-1182, 2003.
- [22] I. Guyon and A. Elisseeff, *An Introduction to variable and feature selection.*: J. Mach. Learn. Res, 2003, vol. 3.
- [23] C. Romero, M. Valdez, and A. Alanis, "A comparative study of machine learning techniques in blog comments spam filtering," *The 2010 International Joint Conference on Neural Networks (IJCNN)*, pp. 1-7, 2010.
- [24] I. Saini, D. Singh, and A. Khosla, "
- [25] OpenCV Dev Team. (2014, Novembro) OpenCV Docs. [Online]. http://docs.opencv.org/3.0-beta/doc/py_tutorials/py_ml/py_knn/py_knn_understanding/py_knn_understanding.html
- [26] J. Ramirez-Cortes, P. Gomez-Gil, V. Alarcon-Aquino, J. Gonzalez-Bernal, and A. Garcia-Pedrero, "Neural networks and SVM-based classification of leukocytes using the morphological pattern spectrum," *Soft Computing for Recognition based on Biometrics, Studies in Computational Intelligence*, 2010.
- [27] OpenCV. (2015, Fevereiro) Introduction to Support Vector Machines. [Online].
http://docs.opencv.org/doc/tutorials/ml/introduction_to_svm/introduction_to_svm.html
- [28] Christopher M. Bishop, *Pattern Recognition and Machine Learning.*: Springer, 2006.
- [29] Y. Liu, J. Lian, M. R. Bartolacci and Q.A. Zeng, "Density-based penalty parameter optimization on c-svm," *The Scientific World Journal*, pp. 814-815, 2014.
- [30] A. R. Webb and K. D. Copsey, *Statistical pattern recognition*, 3rd ed.: Chichester: John Wiley & Sons, 2011.
- [31] Y. Zhang and L. Wu, "Classification of fruits using computer vision and a multiclass support vector

machine," *Sensors*, vol. 12, pp. 12489-12505, 2012.

- [32] R. P. W. Duin, P. Juszczak, P. Paclik, E. Pekalska, D. de Ridder, D. Tax, and S. Verzakov, *PRTools4.1, A Matlab Toolbox for Pattern Recognition.*, 2007.
- [33] J. Rodriguez, A. Perez, and J. Lozano, "Sensitivity analysis of k-fold cross validation in prediction error estimation, "Pattern Analysis and Machine Intelligence," *IEEE Transactions on*, vol. 32, pp. 569–575, 2010.